

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INFORMÁTICA
CIUDAD - CHILE



“ESTUDIO COMPARATIVO SOBRE SIMULACIONES DE POTENCIALES RELACIONADOS CON EVENTOS PARA P300”

JOAQUÍN GABRIEL TORRES CORNEJO

MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL EN INFORMÁTICA

Profesor Guía: Dra. Carolina Saavedra
Profesor Correferente: Dra. Raquel Pezoa

Julio - 2026



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título ☐ Tesis de Postgrado

Título del trabajo: ESTUDIO COMPARATIVO SOBRE SIMULACIONES DE POTENCIALES RELACIONADOS CON EVENTOS PARA P300

Nombre del candidato(a): Joaquín Gabriel Torres Cornejo

Carrera / Grado: Ingeniería Civil Informática

Campus: Casa Central Valparaíso **Departamento:** Informática

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Carolina Saavedra, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

☒ El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☐ 5 años ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 31/07/2026

Firma:

Estudiante o Candidato(a):

Fecha: 31/07/2026

Firma:

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

DEDICATORIA

Agradezco profundamente a mi madre, **Maria Carolina Cornejo Rios**, por su apoyo, paciencia y amor incondicional; su compañía a lo largo de estos años hizo posible este logro. Extiendo mi gratitud a mi abuela, **Georgina Rios Lobos**, y a mi tía, **Rosa Gonzalez Caceres**, cuyo aliento y ayuda fueron fundamentales. Gracias también a mis amigos y compañeros de universidad por su compañía y respaldo constantes.

AGRADECIMIENTOS

Quiero expresar mi más sincero agradecimiento a la profesora Carolina Saavedra, por su inmenso apoyo, su buena onda y por ser una pieza fundamental para ayudarme a sacar adelante esta tesis mientras me encontraba trabajando.

De igual manera, reconozco profundamente a los profesores Héctor Allende y Alejandro Veloz por mostrarme e inculcarme un camino diferente al del desarrollo de software.

Gracias a ustedes, y junto a la profesora Carolina, tuve la invaluable oportunidad de desarrollarme en el área que realmente me apasiona y de tener el honor de ser ayudante de la misma durante dos años.

Un espacio especial y fundamental en estas líneas lo ocupan mis amigos y prácticamente hermanos, Sebastián y Benjamín Reyes. Ustedes me han acompañado casi toda mi vida, y sin su constante respaldo emocional, simplemente no habría podido llegar hasta aquí.

A mi grupo de amigos: Sebastián Torrealba, María Saavedra, Paula Castillo, Martina Tejo, Bruno Bonati, Rock Dabre, Joaquín Véliz, Ignacio Alfaro, Tito Orellana, Joaquín Navarro, Rosario Bregante y Kaled Hernández. Valoro enormemente que estuvieran desde el principio, por el apoyo incondicional entre nosotros y por darnos la fuerza necesaria para sacar adelante esto que se llama carrera.

También hago una mención al grupo de Brujitas Bar, quienes estuvieron desde un inicio apañando siempre, regalándome grandes momentos y muchas risas. A cada uno de ustedes, mi eterna gratitud.

Finalmente, agradezco a todas aquellas personas que ya no están en mi vida porque el destino y Dios así lo quisieron, por las muchas enseñanzas que me dejaron y que siempre llevaré conmigo.

'Where I go I just don't know, I got to got to gotta take it slow'. — Soul to Squeeze, Red Hot Chili Peppers

RESUMEN

Resumen– El desarrollo de interfaces cerebro-computadora basadas en el potencial evocado P300 se ve limitado por la escasez de registros electroencefalográficos empíricos, cuya adquisición es costosa y lenta, lo que resulta insuficiente para entrenar modelos de aprendizaje profundo sin incurrir en sobreajuste. La generación de señales sintéticas surge como una alternativa para mitigar esta limitación, siempre que reproduzca con fidelidad las propiedades de los registros reales. Este trabajo presenta un estudio comparativo de tres modelos de propagación volumétrica de complejidad creciente para la simulación del componente P300: un dipolo en esfera conductora homogénea, el modelo de elementos de frontera (BEM) del NY Head implementado en SEREEGA sobre MATLAB, y el BEM del atlas poblacional fsaverage implementado en MNE-Python. Los tres enfoques se alimentaron con un conjunto unificado de parámetros de entrada, de modo que las diferencias observadas son atribuibles exclusivamente al mecanismo de propagación. Los datos sintéticos se validaron cuantitativamente contra registros empíricos del Dataset II del BCI Competition III, mediante métricas de morfología temporal, distribución topográfica y correlación de forma por canal. Los resultados muestran que el modelo de propagación condiciona de forma determinante la distribución espacial del P300 simulado: los modelos BEM reproducen correctamente la localización del máximo en el canal Cz observada en los datos reales, mientras que el modelo de esfera la sitúa erróneamente en Pz. El análisis identifica cinco brechas de realismo entre los datos sintéticos y los empíricos, que orientan las líneas de mejora del paradigma de simulación.

Palabras Clave— P300; electroencefalografía; simulación de señales EEG; modelos de propagación volumétrica; interfaces cerebro-computadora.

ABSTRACT

Abstract– The development of brain-computer interfaces based on the P300 evoked potential is limited by the scarcity of empirical electroencephalographic recordings, whose acquisition is costly and time-consuming, resulting in insufficient data to train deep learning models without incurring overfitting. The generation of synthetic signals emerges as an alternative to mitigate this limitation, provided it faithfully reproduces the properties of real recordings. This work presents a comparative study of three volume conduction models of increasing complexity for simulating the P300 component: a dipole in a homogeneous conductive sphere, the Boundary Element Method (BEM) of the NY Head implemented in SEREEGA on MATLAB, and the BEM of the fsaverage population atlas implemented in MNE-Python. The three approaches were fed with a unified set of input parameters, so

that the observed differences are exclusively attributable to the propagation mechanism. The synthetic data were quantitatively validated against empirical recordings from Dataset II of the BCI Competition III, using metrics of temporal morphology, topographic distribution, and shape correlation per channel. The results show that the propagation model deterministically conditions the spatial distribution of the simulated P300: the BEM models correctly reproduce the localization of the maximum in the Cz channel observed in the real data, while the sphere model erroneously places it in Pz. The analysis identifies five realism gaps between the synthetic and empirical data, which guide the lines of improvement for the simulation paradigm.

Keywords— P300; electroencephalography; EEG signal simulation; volume conduction models; brain-computer interfaces.

GLOSARIO

AC-PC: Plano de referencia anatómico definido por la comisura anterior y la comisura posterior.

BCI: *Brain-Computer Interface* (Interfaz Cerebro-Computadora).

BEM: *Boundary Element Method* (Método de Elementos de Frontera).

CNN: *Convolutional Neural Network* (Red Neuronal Convolucional).

DC: *Direct Current* (Componente de corriente continua o frecuencia cero).

DI: Departamento de Informática.

EEG: Electroencefalografía / Electroencefalograma.

EEGLAB: *Toolbox* de código abierto para MATLAB destinado al análisis de señales EEG.

ERP: *Event-Related Potential* (Potencial Relacionado con Eventos).

FEM: *Finite Element Method* (Método de Elementos Finitos).

FFT: *Fast Fourier Transform* (Transformada Rápida de Fourier).

ICA: *Independent Component Analysis* (Análisis de Componentes Independientes).

ICBM: *International Consortium for Brain Mapping*.

LCR: Líquido Ceforraquídeo.

LDA: *Linear Discriminant Analysis* (Análisis Discriminante Lineal).

MEG: Magnetoencefalografía.

MNE: *Minimum Norm Estimate*; en este trabajo se refiere a la librería MNE-Python para el análisis de datos MEG/EEG.

MNI: *Montreal Neurological Institute*; sistema de coordenadas estándar para la localización anatómica cerebral.

MRI: *Magnetic Resonance Imaging* (Imagen por Resonancia Magnética).

N100: Componente negativo temprano del ERP, con latencia aproximada de 100 ms.

N200: Componente negativo del ERP, con latencia aproximada de 200 ms.

NY Head: *New York Head*; modelo anatómico de conducción volumétrica de alta resolución.

P200: Componente positivo del ERP, con latencia aproximada de 200 ms.

P300: Componente positivo endógeno del ERP, con latencia aproximada de 300 ms.

P3a: Subcomponente del P300 de distribución frontocentral y latencia más corta.

P3b: Subcomponente del P300 de distribución centroparietal y latencia más prolongada.

PPSE: Potencial Postsináptico Excitatorio.

PPSI: Potencial Postsináptico Inhibitorio.

RMSE: *Root Mean Square Error* (Raíz del Error Cuadrático Medio).

SCCN: *Swartz Center for Computational Neuroscience*.

SEREEGA: *Simulating Event-Related EEG Activity*; *toolbox* de MATLAB para la simulación de actividad EEG.

SNR: *Signal-to-Noise Ratio* (Relación Señal-Ruido).

SVM: *Support Vector Machine* (Máquina de Vectores de Soporte).

UTFSM: Universidad Técnica Federico Santa María.

ÍNDICE DE CONTENIDOS

RESUMEN	III
ABSTRACT	III
GLOSARIO	V
ÍNDICE DE FIGURAS	VIII
ÍNDICE DE TABLAS	VIII
INTRODUCCIÓN	1
CAPÍTULO 1: DEFINICIÓN DEL PROBLEMA	3
1.1 Contexto	3
1.2 La problemática de la adquisición y calidad de datos	4
1.2.1 Costos Operativos y Tiempos Muertos en la Adquisición Empírica	4
1.2.2 Variabilidad Biológica y Fatiga	5
1.2.3 Escasez de Datos para Deep Learning y el Problema del Sobreajuste	6
1.3 Actores Involucrados	7
1.4 Impacto de la Inacción y Justificación	7
1.5 Análisis de la Competencia y Soluciones Existentes	8
1.6 Objetivos de la Memoria	9
1.6.1 Objetivo General	9
1.6.2 Objetivos Específicos	9
CAPÍTULO 2: MARCO CONCEPTUAL	11
2.1 Electroencefalografía: fundamentos neurofisiológicos	11
2.1.1 Origen biofísico de la señal EEG	11
2.1.2 Estructura frecuencial de la señal EEG	12
2.1.3 El Sistema Internacional 10-20 de posicionamiento de electrodos	12
2.2 Potenciales evocados y el componente P300	13
2.2.1 Definición y taxonomía de los potenciales evocados	13
2.2.2 El componente P300: características electrofisiológicas	13
2.2.3 El paradigma oddball	14
2.2.4 Generadores neurales del P300	15
2.3 El problema directo en electroencefalografía	15
2.3.1 Formulación matemática	15
2.3.2 Modelo de esfera conductora homogénea	16
2.3.3 Modelos realistas: el Método de Elementos de Frontera (BEM)	17
2.4 Modelos de cabeza para la resolución del problema directo	18
2.4.1 Panorámica de los modelos existentes	18
2.4.2 Modelo NY Head (ICBM-NY)	19
2.4.3 Modelo fsaverage (FreeSurfer)	19

2.5	Herramientas de software	20
2.5.1	EEGLAB	20
2.5.2	SEREEGA	20
2.5.3	MNE-Python	21
2.6	Generación de señales sintéticas: conceptos clave	22
2.6.1	Modelado del componente P300 como función gaussiana	22
2.6.2	Ruido de fondo: el espectro $1/f$ y la relación señal-ruido	22
CAPÍTULO 3: PROPUESTA: METODOLOGÍA Y DISEÑO EXPERIMENTAL		24
3.1	Parámetros Comunes de la Simulación	24
3.1.1	Montaje de electrodos	24
3.1.2	Localización anatómica de las fuentes dipolares	24
3.1.3	Forma de onda del componente P300	26
3.1.4	Modelo de ruido y variabilidad inter-ensayo	27
3.1.5	Resumen de parámetros de simulación	29
3.2	Tres Modelos de Propagación Volumétrica	30
3.2.1	Modelo 1: Dipolo en esfera conductora homogénea	31
3.2.2	Modelo 2: Leadfield BEM del modelo NY Head (SEREEGA)	31
3.2.3	Modelo 3: fsaverage BEM (MNE-Python)	32
3.3	Validación Estadística contra Datos Reales	32
3.3.1	Dataset de referencia	33
3.3.2	Preprocesamiento: aislamiento del componente P300	33
3.3.3	Métricas de comparación	33
CAPÍTULO 4: RESULTADOS Y ANÁLISIS		35
4.1	Distribuciones del P300 según el Modelo de Propagación	35
4.2	Comparación de las Señales Generadas	37
4.3	Validación contra Datos Reales	41
4.3.1	Resultados de la comparación	41
4.3.2	Diagnóstico de brechas de realismo	44
4.4	Síntesis del Análisis	45
CAPÍTULO 5: CONCLUSIONES Y TRABAJO FUTURO		46
5.1	Conclusiones	46
5.1.1	Implicancias prácticas y teóricas	47
5.1.2	Evaluación comparativa de las plataformas	47
5.2	Limitaciones	48
5.3	Trabajo Futuro	49
5.3.1	Mejoras en la generación de la señal sintética	49
5.3.2	Escalamiento de los modelos de propagación	50
5.3.3	Experimentación avanzada con el potencial P300	50
REFERENCIAS BIBLIOGRÁFICAS		52

ÍNDICE DE FIGURAS

1	Características del componente P300: forma de onda y topografía	14
2	Proyección de las fuentes dipolares sobre el cuero cabelludo	25
3	Formas de onda gaussianas de las fuentes dipolares	27
4	Superposición de épocas individuales y ERP promedio en Pz	28
5	Espectro de potencia del ruido generado	28
6	Comparación topográfica del P300: esfera vs. NY Head BEM	36
7	Topografía del P300 con el modelo fsaverage BEM	37
8	Señal limpia del modelo fsaverage BEM en cuatro canales	38
9	ERP promedio del modelo de esfera homogénea	38
10	ERP promedio del modelo NY Head BEM	39
11	ERP promedio del modelo fsaverage BEM	40
12	Comparación de la morfología temporal del ERP: real vs. sintéticos	42
13	Correlación de Pearson por canal entre ERP sintético y real	43
14	Distribución topográfica normalizada: real vs. sintéticos	44

ÍNDICE DE TABLAS

1	Parámetros comunes de la simulación	30
2	Comparación de los tres modelos de propagación volumétrica	32

INTRODUCCIÓN

Las interfaces cerebro-computadora constituyen una tecnología asistiva que establece una vía de comunicación directa entre la actividad eléctrica cerebral y un dispositivo externo, sin depender de las vías neuromusculares periféricas. Entre los distintos patrones neurológicos empleados para operar estos sistemas, el potencial evocado P300 se ha consolidado como uno de los más fiables, dado que se trata de una respuesta endógena ligada a la atención que no exige entrenamiento intensivo por parte del usuario. El desarrollo de sistemas basados en P300 ha evolucionado desde un problema clínico hacia un problema de procesamiento de señales y reconocimiento de patrones, en el que las arquitecturas de aprendizaje profundo ofrecen un potencial considerable para la detección del componente en condiciones de baja relación señal-ruido.

Este potencial se enfrenta a una barrera estructural: la adquisición empírica de registros de electroencefalografía de alta calidad es un proceso costoso, lento y limitado por la fatiga fisiológica del sujeto, lo que restringe drásticamente el tamaño de las muestras disponibles. Los conjuntos de datos públicos de P300 rara vez superan unas pocas decenas de sujetos, una escala incompatible con las exigencias de las redes neuronales profundas, que demandan grandes volúmenes de datos variados para generalizar correctamente y evitar el sobreajuste. La generación de señales sintéticas surge como una estrategia para mitigar esta escasez, siempre que los datos producidos reproduzcan con fidelidad suficiente las propiedades espaciales y temporales de los registros reales.

La generación de EEG sintético orientado al P300 se apoya en la resolución del problema directo, que calcula el potencial registrado en el cuero cabelludo a partir de fuentes de corriente intracraneales conocidas. La calidad de esta resolución depende del modelo de propagación volumétrica empleado para representar la geometría y las conductividades de los tejidos craneales. Existe un espectro de modelos de complejidad creciente, desde aproximaciones analíticas que tratan la cabeza como una esfera homogénea hasta modelos numéricos que incorporan anatomía realista y conductividades diferenciadas por capa de tejido. La elección entre estos enfoques condiciona las características de los datos generados, pero sus efectos sobre la fidelidad del P300 simulado no suelen evaluarse de forma sistemática ni contrastarse contra registros empíricos.

El presente trabajo aborda esta brecha mediante un estudio comparativo controlado de tres modelos de propagación de distinta complejidad: un dipolo en esfera conductora homogénea, el modelo de elementos de frontera del NY Head implementado en SEREEGA sobre MATLAB, y el modelo de elementos de frontera del atlas poblacional fsaverage implementado en MNE-Python. Los tres enfoques se alimentan con un conjunto unificado de parámetros de entrada, de modo que las diferencias observadas en los datos resultantes son atribuibles exclusivamente al mecanismo de propagación. El objetivo es diagnosticar empíricamente las capacidades y limitaciones de realismo biofísico de cada modelo, identificando en qué dimensiones los simuladores actuales reproducen las características de los datos reales y en

cuáles presentan brechas.

La metodología comprende la definición de un montaje de electrodos, fuentes dipolares, formas de onda y modelo de ruido comunes a los tres enfoques, la generación de los conjuntos de datos sintéticos, y su validación estadística contra registros empíricos de P300 provenientes de un dataset público de referencia. La comparación se realiza sobre la morfología temporal del componente, su distribución topográfica y la correlación de forma por canal, empleando métricas objetivas que cuantifican la similitud entre las señales sintéticas y reales. El análisis de los resultados permite caracterizar las diferencias sistemáticas entre los modelos y diagnosticar las principales brechas de realismo que orientan el trabajo posterior.

El documento se organiza en los siguientes capítulos. El primero define el problema, situándolo en el contexto de las interfaces cerebro-computadora y la escasez de datos, identifica a los actores involucrados y formula los objetivos de la memoria. El segundo desarrolla el marco conceptual, abarcando los fundamentos de la electroencefalografía, las características del componente P300, la formulación del problema directo, los modelos de cabeza disponibles y las herramientas de software empleadas. El tercero presenta el diseño experimental y la metodología, incluyendo los parámetros comunes de simulación, la descripción de los tres modelos de propagación y el procedimiento de validación contra datos reales. El cuarto expone los resultados y su análisis, contrastando las distribuciones generadas por cada modelo y su grado de correspondencia con los registros empíricos. El quinto presenta las conclusiones, las limitaciones del estudio y las líneas de trabajo futuro derivadas de las brechas de realismo identificadas.

CAPÍTULO 1

DEFINICIÓN DEL PROBLEMA

1.1. Contexto

En el ámbito de la informática biomédica y la neurociencia computacional, las Interfaces Cerebro-Computadora, (BCI, por sus siglas en inglés) han emergido como una tecnología asistiva fundamental. Una BCI es un sistema que establece una vía de comunicación directa entre el cerebro humano y un dispositivo externo, como un ordenador o un brazo robótico. Esto se logra capturando la actividad eléctrica generada por las redes neuronales, procesándola mediante algoritmos y traduciéndola en comandos de control ejecutables. La innovación paradigmática de esta tecnología es que permite al usuario interactuar con su entorno sin depender de las vías neuromusculares periféricas, es decir, sin necesidad de activar nervios periféricos ni ejecutar movimientos musculares voluntarios [Wolpaw *et al.*, 2002]. Por consiguiente, su impacto en la calidad de vida de personas con discapacidades motoras severas resulta profundo, ya que les ofrece herramientas para el control de sillas de ruedas, prótesis o sistemas de deletreo virtual que restauran su capacidad de comunicación.

Dentro de los diversos enfoques neurológicos disponibles para operar una BCI, el uso del potencial evocado P300 se ha consolidado como uno de los patrones más fiables y utilizados empíricamente. Un potencial evocado es una respuesta eléctrica transitoria del cerebro que surge como reacción directa a un estímulo específico, ya sea visual, auditivo o táctil. El P300, en particular, consiste en una deflexión positiva en la onda del electroencefalograma (EEG) que ocurre con una latencia de aproximadamente 300 milisegundos tras la presentación de un estímulo. Este fenómeno se explota mediante el paradigma oddball, en el cual el usuario percibe una secuencia continua de estímulos rutinarios interrumpidos esporádicamente por un estímulo relevante, por ejemplo, la iluminación de la letra que desea escribir en una pantalla. El reconocimiento cognitivo de ese estímulo infrecuente es lo que desencadena la onda P300 [Farwell y Donchin, 1988]. Su principal ventaja frente a otros métodos radica en su robustez: al tratarse de una respuesta endógena e involuntaria ligada a la atención natural, no requiere un entrenamiento intensivo por parte del usuario para aprender a modular su actividad cerebral.

Desde la perspectiva de la ingeniería en computación y la inteligencia artificial, el desarrollo de sistemas BCI basados en P300 ha transitado de ser un desafío puramente clínico a un complejo problema de procesamiento de señales, extracción de características y reconocimiento de patrones. La barrera técnica más significativa es la bajísima relación señal-ruido (SNR) inherente al registro EEG. La señal útil, cuya amplitud es micrométrica, se encuentra habitualmente enmascarada por un denso ruido de fondo compuesto por la actividad eléctrica de otras funciones cerebrales ajenas a la tarea, así como por interferencias físicas tales como parpadeos oculares, tensión muscular o ruido electromagnético ambiental. Aislar y detectar el P300 requiere, por tanto, algoritmos computacionales sumamente avan-

zados [Lotte *et al.*, 2018]. Tradicionalmente, este obstáculo se sorteaba empleando técnicas de promediado temporal y clasificadores lineales básicos. Sin embargo, la exigencia actual de lograr tasas de comunicación rápidas y en tiempo real ha impulsado la adopción de arquitecturas de aprendizaje automático y *Deep Learning*. Estos modelos tienen la capacidad de modelar las relaciones no lineales del cerebro sin depender de extracciones manuales de características, aunque introducen una vulnerabilidad crítica: una dependencia de volúmenes masivos de datos variados para ajustar sus parámetros y evitar el sobreajuste.

1.2. La problemática de la adquisición y calidad de datos

A pesar de la sólida fundamentación teórica y la madurez clínica del paradigma P300, la investigación aplicada se enfrenta a un cuello de botella logístico y operativo severo: la adquisición empírica de datos de electroencefalografía (EEG) de alta calidad. Actualmente, obtener un conjunto de datos (dataset) válido implica reclutar extensas cohortes de voluntarios, además de preparar y calibrar equipamiento médico de hardware altamente sensible y ejecutar sesiones de grabación síncronas bajo un control ambiental riguroso.

Esta preparación física exige procedimientos minuciosos, como la abrasión de las células muertas del cuero cabelludo y la aplicación de geles conductores electrolíticos para asegurar que la impedancia de cada canal sea lo suficientemente baja para registrar la señal. Sumado a esto, las sesiones están estrictamente limitadas por la fatiga fisiológica; a medida que el participante se cansa, su nivel de alerta decae y la morfología del P300 se degrada irreversiblemente. Toda esta dependencia de la captura física en pacientes o sujetos sanos presenta dificultades multifactoriales que frenan el avance de la disciplina.

1.2.1. Costos Operativos y Tiempos Muertos en la Adquisición Empírica

A diferencia de la mayoría de los periféricos informáticos modernos, la captura de señales bioeléctricas mediante EEG no es un proceso *plug-and-play* (conectar y usar). La interfaz física entre el cuero cabelludo y el electrodo metálico presenta un desafío biofísico considerable. Se estima que una sesión experimental rigurosa requiere entre 45 y 60 minutos dedicados exclusivamente a la fase de preparación del sujeto, tiempo que varía dependiendo de la densidad topográfica del arreglo de sensores (por ejemplo, configuraciones estándar de 16, 32 o 64 canales) [Teplan, 2002].

Este extenso tiempo de configuración es indispensable debido a la naturaleza anatómica de los tejidos biológicos. La capa externa de la piel (estrato córneo), compuesta por células muertas y sebo natural, actúa como un aislante eléctrico que bloquea las microcorrientes cerebrales. Por ello, el protocolo clínico exige una limpieza abrasiva del cuero cabelludo para remover esta barrera, seguida de la inyección manual de un gel conductivo o pasta electrolítica en cada uno de los electrodos. El objetivo de este meticuloso proceso es establecer

un puente iónico que reduzca la impedancia eléctrica, entendida como la resistencia al flujo de corriente alterna entre el cerebro y el amplificador, por debajo del umbral de $5\text{ k}\Omega$. Este valor es considerado el estándar de oro metodológico para garantizar grabaciones pasivas de alta fidelidad y evitar que la señal sea sepultada por la interferencia electromagnética del ambiente [Kappenman y Luck, 2010].

La suma de este prolongado tiempo preparatorio, considerado un “tiempo muerto” desde la perspectiva computacional de recolección de datos útiles, y la inmovilidad requerida induce una fatiga temprana en el participante antes de siquiera comenzar la tarea cognitiva. Una vez iniciado el experimento, el esfuerzo de atención sostenida degrada progresivamente la morfología de la onda P300 por habituación neurológica, lo que limita aún más la duración efectiva de la sesión útil. Consecuentemente, esta intensa fricción logística restringe de forma drástica la cantidad total de sujetos (tamaño de la muestra, o N) que un equipo de investigación puede procesar en un marco de tiempo y presupuesto razonables.

Como resultado directo de estas barreras operativas, la literatura científica en el ámbito BCI se caracteriza frecuentemente por presentar bases de datos con tamaños de muestra estadísticamente marginales, típicamente inferiores a quince participantes ($N < 15$). Si bien esta escasez de datos podía ser manejable en el pasado para ajustar clasificadores estadísticos tradicionales, resulta estructuralmente incompatible con los estándares actuales de la Inteligencia Artificial. Las arquitecturas de *Deep Learning*, al poseer miles o millones de parámetros internos, demandan volúmenes masivos de información variada para mapear correctamente la inmensa variabilidad inter-sujeto. Un conjunto de datos tan reducido precipita de manera inevitable el fenómeno de sobreajuste (*overfitting*), un escenario crítico donde la red neuronal memoriza el ruido fisiológico particular de esos pocos sujetos de prueba y fracasa rotundamente al intentar generalizar el patrón atencional del P300 frente a nuevos usuarios [Lotte *et al.*, 2018].

1.2.2. Variabilidad Biológica y Fatiga

La señal P300 es un potencial endógeno, lo que significa que es modulada por el estado cognitivo del usuario. Factores como la fatiga, la habituación al estímulo, el aburrimiento o la distracción degradan la amplitud del potencial P300 a medida que avanza la sesión. Esto introduce una “no-estacionariedad” en los datos reales: la señal capturada al inicio de la sesión es morfológicamente distinta a la del final. Este ruido biológico es difícil de etiquetar y limpiar manualmente, resultando en datasets “sucios” que confunden a los clasificadores durante el entrenamiento supervisado.

1.2.3. Escasez de Datos para Deep Learning y el Problema del Sobreajuste

En el panorama tecnológico contemporáneo, existe una profunda asimetría entre las exigencias estructurales de la ciencia de datos moderna y las capacidades reales de recolección de la neurociencia experimental. El cambio de paradigma hacia el aprendizaje profundo (*Deep Learning*) ha revolucionado campos como la Visión por Computador y el Procesamiento de Lenguaje Natural. Arquitecturas de vanguardia, como las Redes Neuronales Convolucionales (CNNs) o los modelos basados en Mecanismos de Atención (*Transformers*), basan su éxito en su capacidad para descubrir representaciones jerárquicas complejas y características latentes de forma automática, eliminando la necesidad de que un ingeniero extraiga características manualmente.

Sin embargo, esta enorme capacidad de representación matemática tiene un costo ineludible: una dependencia absoluta de datos. Mientras que los modelos de visión artificial se entrenan rutinariamente con bases de datos públicas que contienen decenas de millones de imágenes (como ImageNet), el dominio de las Interfaces Cerebro-Computadora se enfrenta a una sequía de información severa. Debido a las fricciones logísticas y la fatiga del usuario mencionadas anteriormente, un *dataset* empírico de P300 típicamente exhaustivo y de libre acceso apenas logra recopilar información de entre 10 y 20 sujetos, con unos pocos cientos de intentos (*trials*) útiles por cada participante. En total, la red neuronal recibe apenas unos pocos miles de ejemplos fragmentados e inmersos en un mar de ruido electromagnético.

Esta escasez estructural choca matemáticamente con la arquitectura del aprendizaje profundo. Las redes neuronales profundas contemporáneas poseen desde cientos de miles hasta decenas de millones de parámetros internos (pesos y sesgos) que necesitan ser ajustados iterativamente durante el entrenamiento. Al forzar a estas redes a aprender de una muestra de datos tan minúscula, la capacidad de memorización del modelo supera con creces la cantidad de información útil del *dataset*.

Esto desencadena un fenómeno estadístico crítico conocido como sobreajuste (*overfitting*). En lugar de aprender a abstraer las propiedades topográficas y temporales generales del componente P300, el modelo aprovecha su exceso de parámetros para memorizar la “huella digital” del ruido. La red aprende a identificar las fluctuaciones de la línea base, las interferencias musculares específicas y la configuración exacta de la impedancia de los pocos sujetos utilizados en la fase de entrenamiento.

Como resultado directo de este sobreajuste espurio, el modelo alcanza precisiones artificialmente altas durante las pruebas de laboratorio cerradas, pero fracasa de forma rotunda en la fase de inferencia al enfrentarse a un usuario nuevo o a una sesión en un día diferente (*Out-of-Distribution failure*). Esta barrera estructural de datos es el principal techo de cristal que ha impedido que la comunidad científica traduzca los avances de la IA moderna en sistemas BCI robustos, generalizables y viables para su uso clínico y cotidiano, justificando de forma imperativa la necesidad de explorar paradigmas de simulación y aumento de datos sintéticos.

1.3. Actores Involucrados

La carencia de herramientas de simulación y la dificultad de acceso a datos afecta a un ecosistema específico de actores dentro de la comunidad científica y tecnológica:

- **Investigadores Académicos y Tesistas:** Constituyen el grupo mayoritario. En proyectos de análisis de señales biomédicas, una fracción sustancial del tiempo se destina a la preparación, limpieza y etiquetado de los registros EEG, lo que reduce considerablemente el tiempo disponible para el desarrollo y evaluación de algoritmos de clasificación.
- **Desarrolladores de Algoritmos BCI:** Ingenieros que requieren validar la robustez de sus modelos ante condiciones de ruido específicas (por ejemplo, probar si un algoritmo resiste artefactos de parpadeo) que son difíciles de replicar de manera controlada en sujetos reales.
- **Laboratorios con Recursos Limitados:** Grupos de investigación en países en desarrollo o instituciones pequeñas que no poseen amplificadores de grado médico/investigación (cuyos costos pueden partir aproximadamente en los \$20,000 USD, dependiendo de la configuración) y dependen exclusivamente de bases de datos públicas estáticas, limitando su capacidad de experimentar con nuevas configuraciones experimentales.

1.4. Impacto de la Inacción y Justificación

Si las dificultades inherentes a la adquisición de datos empíricos no se abordan mediante metodologías de simulación accesibles y biofísicamente realistas, se prevén consecuencias severas para el desarrollo de las Interfaces Cerebro-Computadora a corto y mediano plazo:

1. **Estancamiento en la Innovación Algorítmica:** Sin acceso a volúmenes masivos de datos diversos y representativos, la investigación continuará confinada a clasificadores estadísticos lineales (LDA, SVM), marginando el potencial de las arquitecturas de *Deep Learning* para descifrar las representaciones espaciotemporales no lineales del cerebro.
2. **Falta de Estandarización y Validación Objetiva:** Al carecer de una “verdad absoluta” (*ground truth*) en los registros empíricos, dada la incertidumbre sobre el nivel real de atención del usuario en un ensayo específico, resulta inviable comparar con rigor el rendimiento de distintos algoritmos de filtrado espacial. La simulación provee el único marco de referencia estrictamente controlado para este fin.

Por lo tanto, la justificación de este trabajo radica en la necesidad imperativa de evaluar y comprender a fondo las capacidades y limitaciones de las herramientas de generación de datos sintéticos actuales. Al realizar un estudio comparativo riguroso de las metodologías de simulación predominantes, esta memoria busca identificar con precisión las brechas tecnológicas que causan la actual esterilidad de los *datasets* artificiales frente a la complejidad biológica real. Este diagnóstico crítico no solo orienta a la comunidad investigadora en la selección fundamentada de simuladores para el pre-entrenamiento de modelos, sino que también sienta las bases teóricas y estructurales para proponer futuras mejoras o integraciones que logren reducir la dependencia de cohortes humanas y acelerar el ciclo de validación de nuevas tecnologías.

1.5. Análisis de la Competencia y Soluciones Existentes

La simulación de señales EEG es una práctica establecida para abordar la escasez empírica de datos en el desarrollo de Interfaces Cerebro-Computadora (BCI). En el estado del arte actual, coexisten diversas herramientas que abordan este problema desde enfoques metodológicos y ecosistemas tecnológicos distintos, lo que presenta un terreno fértil para la investigación y experimentación.

Por un lado, destacan plataformas paramétricas consolidadas bajo licencias propietarias, como SEREEGA [Krol *et al.*, 2018](basada en MATLAB), las cuales se caracterizan por su enfoque analítico en la resolución del problema directo y su control sobre la morfología del potencial P300. Esta plataforma ofrece, además, múltiples niveles de complejidad en el modelo de propagación: desde aproximaciones simplificadas basadas en dipolo en esfera conductora homogénea, hasta matrices de *leadfield* derivadas de modelos anatómicos realistas como el NY Head, resueltos mediante el método de elementos de contorno (BEM). Por otro lado, emergen ecosistemas *open-source* nativos en Python, como MNE-Python, que priorizan la interoperabilidad arquitectónica con librerías modernas de procesamiento masivo de datos y aprendizaje automático, y que disponen de su propio modelo anatómico estándar (*fsaverage*) con solución BEM precalculada.

Frente a esta diversidad de opciones, surge la necesidad de evaluar empíricamente cuál de estas metodologías produce datos sintéticos con mayor fidelidad biofísica. En lugar de asumir sus alcances o limitantes a priori, el objetivo es evaluar mediante experimentación práctica cómo los distintos modelos de propagación, desde la aproximación analítica más simple hasta los modelos BEM de ambos ecosistemas, manejan la generación espacial y temporal de las señales, y contrastar los datos resultantes con registros empíricos reales de P300. Este estudio comparativo permitirá determinar en qué dimensiones los simuladores actuales logran reproducir las características de los datos reales y en cuáles presentan brechas que deberán ser abordadas en etapas posteriores.

1.6. Objetivos de la Memoria

Considerando la problemática de la escasez de datos empíricos y la necesidad de evaluar la calidad de los conjuntos de datos sintéticos generados por las herramientas de simulación disponibles, se definen los siguientes objetivos para el proyecto:

1.6.1. Objetivo General

Evaluar comparativamente metodologías del estado del arte para la simulación de señales electroencefalográficas (EEG) orientadas al potencial evocado P300, con el fin de diagnosticar empíricamente sus capacidades y limitaciones de realismo biofísico, contrastando tres niveles de complejidad en el modelo de propagación: dipolo en esfera conductora, *leadfield* BEM del modelo NY Head (SEREEGA/MATLAB) y *leadfield* BEM del modelo fsaverage (MNE-Python).

1.6.2. Objetivos Específicos

- **Analizar el estado del arte** de las herramientas de simulación de señales EEG (SEREEGA y MNE-Python), comprendiendo sus fundamentos matemáticos subyacentes para la resolución del problema directo y la generación de componentes ERP/P300.
- **Diseñar y ejecutar un entorno experimental comparativo** que permita contrastar empíricamente la fidelidad espacial y la variabilidad temporal (*jitter*) de los datos sintéticos generados por tres modelos de propagación de distinta complejidad: dipolo en esfera conductora homogénea, *leadfield* BEM basado en el modelo NY Head y *leadfield* BEM basado en el modelo fsaverage.
- **Implementar y contrastar la generación de datos sintéticos** en dos ecosistemas tecnológicos distintos (MATLAB/SEREEGA y Python/MNE-Python), documentando las diferencias arquitectónicas en cuanto a modularidad, configuración del modelo de cabeza y formatos de salida, y verificando que ambos ecosistemas producen datos estructuralmente equivalentes a partir de los mismos parámetros de entrada.
- **Diagnosticar las brechas de realismo biofísico** en los conjuntos de datos generados, documentando específicamente la capacidad de las herramientas actuales para emular dinámicas no estacionarias complejas, como la fatiga cognitiva progresiva, la correlación espacial del ruido entre canales y la superposición de artefactos musculares u oculares.
- **Formular una propuesta conceptual** para un paradigma de simulación que aborde las brechas identificadas, discutiendo posibles líneas de trabajo futuro que incluyan

la integración del *ground truth* espacial de los modelos paramétricos evaluados con técnicas complementarias de aumento de datos.

CAPÍTULO 2

MARCO CONCEPTUAL

2.1. Electroencefalografía: fundamentos neurofisiológicos

La electroencefalografía (EEG) es una técnica de neuroimagen no invasiva que registra la actividad eléctrica cerebral mediante electrodos colocados sobre el cuero cabelludo. La señal capturada no proviene de neuronas individuales, sino de la actividad sincrónica de grandes poblaciones de neuronas piramidales orientadas perpendicularmente a la superficie cortical. Cuando miles de estas neuronas se activan simultáneamente, sus corrientes postsinápticas se suman y generan campos eléctricos lo suficientemente intensos como para ser detectados en la superficie craneal [Niedermeyer y da Silva, 2004]. La señal resultante presenta amplitudes del orden de los microvoltios (μV) y un rango de frecuencias que abarca típicamente desde 0.5 hasta 100 Hz [Teplan, 2002].

2.1.1. Origen biofísico de la señal EEG

La generación de la señal EEG se fundamenta en los potenciales postsinápticos excitatorios e inhibitorios (PPSE y PPSI, respectivamente) que ocurren en las dendritas apicales de las neuronas piramidales de la corteza cerebral. Cuando un neurotransmisor se libera en una sinapsis, provoca un flujo de iones a través de la membrana celular que genera una corriente primaria intracelular. Para mantener la conservación de carga, se establece simultáneamente una corriente de retorno extracelular de sentido opuesto, denominada corriente volumétrica. Esta configuración de corrientes primarias y de retorno constituye un dipolo de corriente equivalente, que es la unidad elemental del modelo biofísico utilizado para representar la actividad neural en la superficie cortical [Nunez y Srinivasan, 2006].

La clave para que esta actividad sea detectable a nivel del cuero cabelludo reside en la geometría columnar de la corteza cerebral. Las neuronas piramidales están organizadas en columnas perpendiculares a la superficie cortical, de modo que sus dipolos se alinean geométricamente. Cuando una población de aproximadamente 10^4 a 10^5 neuronas piramidales vecinas se activa de manera sincrónica, sus dipolos individuales se suman coherentemente, generando un dipolo equivalente macroscópico cuyo campo eléctrico puede propagarse a través de los tejidos hasta alcanzar los electrodos de superficie. Las neuronas que no mantienen esta orientación coherente (como las interneuronas o las neuronas estrelladas) contribuyen de manera marginal a la señal de superficie, ya que sus campos tienden a cancelarse mutuamente [Nunez y Srinivasan, 2006].

2.1.2. Estructura frecuencial de la señal EEG

La señal EEG se caracteriza por una distribución espectral que sigue una ley de potencia inversa, comúnmente denominada espectro $1/f$: la densidad espectral de potencia decae proporcionalmente al inverso de la frecuencia. Este comportamiento implica que las oscilaciones de baja frecuencia concentran la mayor parte de la energía del registro, mientras que las frecuencias altas contribuyen progresivamente menos [Buzsáki, 2006]. Tradicionalmente, el espectro EEG se descompone en bandas de frecuencia con significado funcional: delta (δ , 0.5–4 Hz), theta (θ , 4–8 Hz), alfa (α , 8–13 Hz), beta (β , 13–30 Hz) y gamma (γ , 30–100 Hz). Cada banda se asocia con estados cognitivos y fisiológicos distintos; por ejemplo, la banda alfa predomina durante estados de vigilia relajada con ojos cerrados, mientras que la actividad beta se incrementa durante tareas de concentración activa.

La relevancia de esta estructura espectral para el presente trabajo es directa: cualquier simulador que pretenda generar señales EEG realistas debe reproducir la pendiente $1/f$ del ruido de fondo. Un ruido blanco (distribución plana en frecuencia) no es representativo de la actividad cerebral real y produciría datos sintéticos que los clasificadores modernos podrían distinguir fácilmente de registros empíricos, invalidando su utilidad como herramienta de aumento de datos.

2.1.3. El Sistema Internacional 10-20 de posicionamiento de electrodos

Para garantizar la reproducibilidad de los registros entre laboratorios y sujetos, la Federación Internacional de Neurofisiología Clínica adoptó el Sistema Internacional 10-20 como estándar de posicionamiento de electrodos [Jasper, 1958]. Este sistema define las posiciones de los electrodos como porcentajes (10 % y 20 %) de las distancias medidas entre puntos anatómicos de referencia craneales: el nasión (depresión entre la frente y la nariz), el inión (protuberancia occipital) y los puntos preauriculares (depresiones anteriores a los tragos de las orejas).

El montaje estándar de 19 canales, utilizado en la experimentación de esta memoria, incluye posiciones distribuidas en cinco regiones anatómicas: frontal (Fp1, Fp2, F3, Fz, F4, F7, F8), central (C3, Cz, C4), temporal (T7, T8), parietal (P3, Pz, P4, P7, P8) y occipital (O1, O2). Cada etiqueta codifica información espacial: la letra indica la región cerebral, los números impares corresponden al hemisferio izquierdo, los pares al derecho, y la letra “z” denota la línea media. Este esquema de nomenclatura permite localizar sin ambigüedad la posición de cada electrodo y es reconocido por la totalidad de las herramientas de software utilizadas en este trabajo (EEGLAB, SEREEGA, MNE-Python).

Extensiones posteriores del sistema, como el 10-10 y el 10-05, subdividen las distancias en porcentajes menores para acomodar montajes de mayor densidad (64, 128 o 256 canales). En particular, el modelo NY Head utilizado por SEREEGA emplea un montaje de 228 canales del sistema 10-05, del cual se extraen los 19 canales del montaje estándar para la experi-

mentación comparativa.

2.2. Potenciales evocados y el componente P300

2.2.1. Definición y taxonomía de los potenciales evocados

Un potencial evocado (PE, o ERP por sus siglas en inglés: *Event-Related Potential*) es una respuesta eléctrica cerebral estereotipada que se produce como reacción temporal directa a un evento sensorial, cognitivo o motor específico. A diferencia de las oscilaciones espontáneas del EEG de fondo, cuya fase y amplitud varían de manera aleatoria entre ensayos, los ERPs presentan una relación temporal fija con el estímulo desencadenante. Esta propiedad de acoplamiento temporal (time-locking) es la que permite extraerlos del ruido de fondo mediante la técnica de promediado coherente: al alinear y promediar múltiples ensayos respecto al momento del estímulo, la actividad EEG no relacionada (cuya fase es aleatoria) tiende a cancelarse, mientras que la respuesta evocada (cuya fase es constante) se preserva y emerge con claridad [Luck, 2014].

Los ERPs se clasifican en dos categorías fundamentales según su mecanismo generador. Los potenciales exógenos son respuestas tempranas (latencia inferior a 100 ms) determinadas principalmente por las propiedades físicas del estímulo (intensidad, modalidad sensorial) y relativamente insensibles al estado cognitivo del sujeto. Los potenciales endógenos, en cambio, son respuestas tardías (latencia superior a 100 ms) moduladas por factores cognitivos como la atención, la expectativa y la relevancia subjetiva del estímulo. El componente P300 pertenece a esta segunda categoría [Luck, 2014, Polich, 2007].

2.2.2. El componente P300: características electrofisiológicas

El P300 es un potencial endógeno que se manifiesta como una deflexión positiva de gran amplitud en la señal EEG, con una latencia típica de entre 250 y 500 milisegundos tras la presentación de un estímulo relevante para la tarea. Su nombre codifica dos propiedades: la polaridad positiva (P) y la latencia aproximada en milisegundos (300). El componente fue descrito por primera vez por Sutton et al. en 1965 [Sutton *et al.*, 1965] y desde entonces se ha convertido en uno de los marcadores electrofisiológicos más estudiados y mejor caracterizados en la literatura neurocientífica.

Desde el punto de vista topográfico, la distribución del P300 sobre el cuero cabelludo presenta su máxima amplitud en la región centro-parietal (electrodos Cz, Pz), con una distribución relativamente simétrica entre ambos hemisferios. La amplitud típica oscila entre 5 y 20 μ V en registros promediados, aunque este valor es altamente variable entre sujetos y depende de factores como la edad, el nivel de atención, la dificultad de la tarea y la probabilidad del

estímulo objetivo [Polich, 2007]. Ambas características esenciales, tanto la morfología temporal de la onda como su distribución espacial, se encuentran ilustradas detalladamente en la Figura 1.




Figura 1: Componente P300: (A) forma de onda ERP típica en Pz con sus componentes (N100, P200, N200, P300) y la ventana del P300 sombreada; (B) distribución topográfica, con máximo en la región centro-parietal (Cz, Pz).

Se distinguen dos subcomponentes del P300 con generadores y distribuciones topográficas parcialmente diferenciables. El P3a, con distribución frontocentral y latencia más corta (250–280 ms), se asocia con la detección involuntaria de estímulos novedosos o inesperados y se genera principalmente en regiones frontales y del cíngulo anterior. El P3b, con distribución centroparietal y latencia más prolongada (300–500 ms), refleja procesos de actualización de la memoria de trabajo y evaluación consciente de la relevancia del estímulo, con generadores distribuidos en la corteza parietal posterior y el cíngulo posterior [Polich, 2007]. En el contexto de las interfaces cerebro-computadora, es el componente P3b el que se explota predominantemente, ya que su elicitación depende de la atención voluntaria del usuario.

2.2.3. El paradigma oddball

El método experimental estándar para elicitar el P300 es el paradigma *oddball*, descrito originalmente por Farwell y Donchin (1988) en el contexto de las BCI [Farwell y Donchin, 1988]. En este paradigma, el sujeto es expuesto a una secuencia continua de estímulos que se dividen en dos categorías: estímulos frecuentes (o estándar), que constituyen la mayoría de las presentaciones (típicamente el 80–85 %), y estímulos infrecuentes (o target), que aparecen de manera esporádica (15–20 %). El sujeto tiene la instrucción de atender selectivamente a los estímulos infrecuentes, ya sea contándolos mentalmente o ejecutando una respuesta motora.

La violación de la expectativa estadística generada por la regularidad de los estímulos frecuentes es el mecanismo cognitivo que desencadena la onda P300 ante cada estímulo infrecuente. En la implementación clásica de un speller BCI (deletreador), se presenta una matriz de caracteres alfanuméricos en pantalla y se iluminan filas y columnas de manera aleatoria. El usuario enfoca su atención en la letra que desea comunicar; cuando la fila o columna que contiene esa letra se ilumina (evento infrecuente respecto al total de iluminaciones), se genera un P300 detectable que el sistema utiliza para identificar el carácter objetivo [Farwell y Donchin, 1988].

2.2.4. Generadores neurales del P300

La localización de los generadores del P300 ha sido objeto de extenso estudio mediante técnicas de localización de fuentes, registros intracerebrales y lesiones focales. La evidencia convergente sugiere que el P300 no es generado por una única fuente puntual, sino por una red distribuida de regiones corticales y subcorticales que se activan de manera secuencial [Polich, 2007].

Para el subcomponente P3b, los principales generadores se localizan en la corteza parietal posterior (áreas de Brodmann 7, 39 y 40), la corteza temporal medial (incluyendo el hipocampo) y el cíngulo posterior. El cíngulo posterior, en particular, desempeña un papel relevante como generador profundo cuya contribución al potencial de superficie depende críticamente del modelo de propagación volumétrica utilizado, una observación directamente pertinente para la experimentación de esta memoria.

En el diseño experimental de este trabajo, se modelaron dos fuentes dipolares que representan estos generadores: un dipolo parietal (en adelante, **Fuente 1**) localizado en coordenadas MNI (*Montreal Neurological Institute*) $[0; -60; 40]$ mm, representando la actividad del lóbulo parietal superior, y un dipolo cíngulo (**Fuente 2**) en $[0; -45; 25]$ mm, representando el cíngulo posterior. Ambas coordenadas están justificadas por estudios de localización de fuentes del P300 reportados en la literatura [Polich, 2007].

2.3. El problema directo en electroencefalografía

2.3.1. Formulación matemática

El problema directo (forward problem) en EEG consiste en calcular la distribución de potenciales eléctricos en la superficie del cuero cabelludo (es decir, en los electrodos) a partir del conocimiento de las fuentes de corriente intracraneales y de las propiedades geométricas y eléctricas de los tejidos intermedios. Matemáticamente, este problema se fundamenta en las ecuaciones cuasiestáticas de Maxwell, válidas para el rango de frecuencias del EEG (inferior a 1 kHz), donde los efectos de propagación electromagnética son despreciables y el

campo eléctrico puede tratarse como un campo conservativo derivable de un potencial escalar [Hallez *et al.*, 2007].

Para un conjunto de K fuentes dipolares con momentos $\mathbf{q}_k$ ubicadas en posiciones $\mathbf{r}_k$ dentro del volumen conductor, el potencial $V(\mathbf{r}_i)$ medido en el electrodo ubicado en la posición $\mathbf{r}_i$ viene dado por la relación lineal:

$$V(\mathbf{r}_i) = \sum_{k=1}^K \mathbf{L}(\mathbf{r}_i, \mathbf{r}_k) \cdot \mathbf{q}_k \quad (1)$$

donde $\mathbf{r}_k$ denota la posición de la fuente k y $\mathbf{r}_i$ la posición del electrodo i . Es crucial destacar que ambas posiciones deben estar definidas en un mismo sistema de coordenadas espaciales para calcular correctamente su distancia y orientación relativa. En el contexto de este trabajo, los vectores de posición se expresan en milímetros (mm) con respecto al origen del espacio anatómico estándar MNI (Montreal Neurological Institute), situado anatómicamente en la comisura anterior. En este sistema, los ejes X , Y y Z definen las direcciones lateral, anterior-posterior y superior-inferior, respectivamente, garantizando la coherencia geométrica entre la fuente interna y el sensor superficial.

Por su parte, $\mathbf{q}_k$ representa el momento dipolar de la fuente k . La función $\mathbf{L}(\mathbf{r}_i, \mathbf{r}_k)$ es el *lead-field*, que codifica la relación espacial y electromagnética entre la fuente k y el sensor i , la cual depende estrictamente de la geometría y conductividad del medio. En notación matricial, para N electrodos y K fuentes tridimensionales, esta relación se expresa como:

$$\mathbf{V} = \mathbf{L} \cdot \mathbf{Q} \quad (2)$$

donde $\mathbf{V} \in R^N$ es el vector de potenciales, $\mathbf{L} \in R^{N \times 3K}$ es la matriz de *leadfield*, y $\mathbf{Q} \in R^{3K}$ es el vector que concatena los momentos dipolares de todas las fuentes. La linealidad de esta relación es una propiedad fundamental: permite superponer las contribuciones de múltiples fuentes y constituye la base matemática de toda la simulación realizada en esta memoria [Hallez *et al.*, 2007].

2.3.2. Modelo de esfera conductora homogénea

El modelo más simple para resolver el problema directo es la esfera conductora homogénea, que aproxima la cabeza como un volumen esférico de conductividad uniforme σ . Para este caso, existen soluciones analíticas cerradas derivadas del potencial de Coulomb. El potencial generado por un dipolo de corriente $\mathbf{q}$ ubicado en la posición $\mathbf{r}_d$ dentro de la esfera, medido en un electrodo en la posición $\mathbf{r}_i$ sobre la superficie, se calcula como:

$$V_i = \frac{1}{4\pi\sigma} \frac{(\mathbf{r}_i - \mathbf{r}_d) \cdot \mathbf{q}}{|\mathbf{r}_i - \mathbf{r}_d|^3} \quad (3)$$

Este modelo ofrece simplicidad computacional y transparencia matemática, pero presenta limitaciones fundamentales de realismo. Al asumir una conductividad uniforme para todo el volumen, no modela las interfaces entre tejidos con conductividades marcadamente diferentes: cerebro ($\sigma \approx 0,33$ S/m), líquido cefalorraquídeo ($\sigma \approx 1,79$ S/m), cráneo ($\sigma \approx 0,0042$ S/m) y cuero cabelludo ($\sigma \approx 0,33$ S/m) [Geddes y Baker, 1967]. En particular, el cráneo presenta una conductividad aproximadamente 80 veces menor que la del cerebro, y actúa como una capa aislante que atenúa y dispersa espacialmente las corrientes eléctricas. Al omitir este efecto, el modelo de esfera produce topografías artificialmente focalizadas para fuentes profundas, lo que constituye una limitación reconocida en la literatura que debe considerarse al evaluar la fidelidad de las simulaciones generadas con este enfoque.

2.3.3. Modelos realistas: el Método de Elementos de Frontera (BEM)

Para superar las limitaciones del modelo de esfera, se recurre a modelos volumétricos realistas que incorporan la geometría anatómica y las conductividades diferenciadas de los tejidos. El Método de Elementos de Frontera (BEM, *Boundary Element Method*) es la técnica numérica más utilizada para resolver el problema directo con anatomía realista en el contexto del EEG [Hallez *et al.*, 2007].

El BEM modela el volumen conductor como un conjunto de regiones homogéneas por capas, separadas por superficies de contorno (interfaces) que se discretizan como mallas triangulares. Las ecuaciones de contorno electromagnéticas se resuelven numéricamente en cada interfaz, respetando las condiciones de continuidad del potencial y de la componente normal de la densidad de corriente. El resultado de este cálculo es una matriz de *leadfield* $\mathbf{L}$ que mapea exhaustivamente la contribución de cada posible fuente cortical a cada electrodo del montaje.

A diferencia del modelo de esfera, el BEM captura tres fenómenos biofísicos que alteran significativamente la topografía resultante: la atenuación diferencial de la señal al atravesar el cráneo, la dispersión espacial de las corrientes en la interfaz cráneo-cuero cabelludo, y la canalización de corrientes a través de estructuras anatómicas como las suturas craneales o los agujeros de la base del cráneo. Estos efectos son especialmente relevantes para fuentes profundas como el cíngulo posterior, cuya contribución al potencial de superficie es más dependiente de la geometría craneal que las fuentes corticales superficiales.

2.4. Modelos de cabeza para la resolución del problema directo

La resolución del problema directo requiere un modelo volumétrico que describa la geometría y las propiedades conductivas de los tejidos craneales. En la literatura existe un espectro de modelos de complejidad creciente, cada uno con compromisos distintos entre fidelidad anatómica, costo computacional y accesibilidad en los ecosistemas de software disponibles.

2.4.1. Panorámica de los modelos existentes

En el nivel más simple se encuentra el modelo de esfera conductora homogénea, descrito en la sección anterior, que admite solución analítica cerrada pero ignora por completo la diferenciación de tejidos. Un paso intermedio lo constituyen los modelos de esferas concéntricas, que representan la cabeza como tres o cuatro capas esféricas anidadas (cerebro, líquido cefalorraquídeo, cráneo y cuero cabelludo), cada una con su propia conductividad. Estos modelos siguen admitiendo soluciones analíticas eficientes y capturan el efecto atenuante del cráneo, pero su geometría esférica no reproduce la forma real de la cabeza. Están disponibles en la mayoría de los entornos de análisis, incluyendo FieldTrip, Brainstorm y BESA. Una variante refinada es el modelo de esferas solapadas (*overlapping spheres*), que ajusta una esfera local bajo cada sensor para aproximar mejor la curvatura craneal en cada punto de medición; este enfoque es el método por defecto de Brainstorm para datos de magnetoencefalografía.

En el siguiente nivel de realismo se sitúan los modelos numéricos basados en el Método de Elementos de Frontera (BEM), que utilizan mallas triangulares extraídas de imágenes de resonancia magnética para representar las interfaces reales entre tejidos. Entre los modelos BEM de referencia más utilizados se encuentran: el Colin27, construido a partir de 27 escaneos de un único sujeto y disponible como plantilla en LORETA, EEGLAB-NFT, Brainstorm y Field-Trip; el NY Head (ICBM-NY), basado en el atlas ICBM152 con segmentación de seis tejidos [Huang *et al.*, 2016], accesible a través de SEREEGA; y el fsaverage, derivado del promedio de 40 sujetos del proyecto FreeSurfer y accesible nativamente en MNE-Python.

Finalmente, los modelos basados en el Método de Elementos Finitos (FEM) representan el nivel más alto de detalle, ya que discretizan el volumen completo en elementos tetraédricos y permiten modelar conductividades anisotrópicas dentro de cada tejido. El propio NY Head fue originalmente resuelto como un FEM de seis tejidos a una resolución de 0.5 mm^3 . En el ecosistema de software, los modelos FEM son accesibles mediante SimBio (integrado en FieldTrip) y DUNEuro (integrado en Brainstorm), aunque su costo computacional significativamente mayor limita su adopción en flujos de trabajo de simulación masiva.

A continuación se describen en detalle los dos modelos BEM de mayor relevancia para la simulación de señales EEG con *ground truth* conocido.

2.4.2. Modelo NY Head (ICBM-NY)

El modelo NY Head (*New York Head*) es un modelo anatómico de conducción volumétrica de alta resolución construido por el grupo de investigación de Lucas Parra en el City College of New York. Fue generado a partir de imágenes de resonancia magnética (MRI) de alta resolución del proyecto ICBM (International Consortium for Brain Mapping), segmentadas en seis tipos de tejido: materia gris, materia blanca, líquido cefalorraquídeo (LCR), cráneo (compacto y esponjoso), cuero cabelludo y cavidades de aire [Huang *et al.*, 2016].

La solución BEM del NY Head fue precalculada utilizando el software OpenMEEG [Huang *et al.*, 2016] con tres superficies de contorno (cerebro-LCR, LCR-cráneo, cráneo-cuero cabelludo) y una resolución de 74,382 posiciones de fuente distribuidas sobre la superficie cortical. La matriz de *leadfield* resultante tiene dimensiones $[228 \times 74,382 \times 3]$, donde 228 es el número de electrodos del sistema extendido 10-05 y 3 corresponde a las tres componentes cartesianas de orientación de cada dipolo fuente. En el ecosistema SEREEGA, esta matriz se encuentra disponible a través del archivo `sa_nyhead.mat` y de la función `lf_generate_fromnyhead`.

Una característica relevante del NY Head es que, al estar basado en la anatomía del atlas ICBM152, preserva detalles anatómicos de alta resolución: asimetrías hemisféricas, grosor variable del cráneo y geometría específica de las circunvoluciones corticales. Esto lo convierte en un modelo de alta fidelidad anatómica, pero también implica que las topografías generadas pueden reflejar particularidades estructurales que no necesariamente se generalizan a toda la población.

2.4.3. Modelo fsaverage (FreeSurfer)

El modelo fsaverage es un atlas cerebral promedio derivado de la segmentación y alineamiento de las imágenes de resonancia magnética de 40 sujetos adultos sanos, realizado mediante el software FreeSurfer [Fischl, 2012]. A diferencia del NY Head, fsaverage no representa la anatomía de un individuo ni de un atlas único, sino un promedio poblacional que suaviza las variaciones individuales y conserva únicamente las características anatómicas compartidas.

El modelo incluye superficies trianguladas para las tres capas de tejido requeridas por el BEM (cuero cabelludo, cráneo y cerebro), junto con una solución BEM precalculada que MNE-Python expone mediante la función `mne.read_bem_solution`. El espacio de fuentes estándar consiste en 10,242 posiciones por hemisferio (20,484 en total), distribuidas sobre la superficie cortical con una distancia promedio entre vecinos de aproximadamente 3.1 mm [Gramfort *et al.*, 2013, Gramfort *et al.*, 2014].

Al representar un promedio poblacional, las topografías generadas con fsaverage tienden a ser más representativas de la población general que las de un modelo individual. Sin em-

bargo, el proceso de promediado inevitablemente suaviza detalles anatómicos finos, lo que puede resultar en topografías menos focalizadas comparadas con las de un modelo basado en una anatomía específica de mayor resolución.

2.5. Herramientas de software

2.5.1. EEGLAB

EEGLAB es un toolbox de código abierto para MATLAB desarrollado en el Swartz Center for Computational Neuroscience (SCCN) de la Universidad de California en San Diego. Desde su publicación inicial, se ha consolidado como la plataforma de referencia para el procesamiento y análisis de señales EEG en el entorno MATLAB, acumulando miles de citas en la literatura neurocientífica [Delorme y Makeig, 2004]. El toolbox proporciona funcionalidades que abarcan la totalidad del pipeline de análisis EEG: importación de datos de múltiples formatos, gestión de montajes de electrodos, filtrado temporal, segmentación en épocas, rechazo de artefactos, análisis de componentes independientes (ICA), análisis espectral y visualización topográfica.

En el contexto de esta memoria, EEGLAB cumple dos funciones específicas. En primer lugar, proporciona la infraestructura para la configuración del montaje de 19 canales: la función `pop_chanedit` asigna coordenadas tridimensionales a cada electrodo a partir del archivo `standard_1005.elc`, incluido en el complemento DIPFIT. En segundo lugar, sus funciones de visualización (`topoplot` y `headplot`) se utilizan para generar las representaciones topográficas bidimensionales y tridimensionales que permiten validar tanto el montaje como las topografías de las señales simuladas.

2.5.2. SEREEGA

SEREEGA (*Simulating Event-Related EEG Activity*) es un *toolbox* de código abierto para MATLAB dedicado específicamente a la generación de datos EEG simulados con *ground truth* conocido. Fue desarrollado por Krol et al. (2018) en la Technische Universität Berlin y publicado en el *Journal of Neuroscience Methods* [Krol et al., 2018]. Su diseño modular permite definir fuentes cerebrales, asignarles señales de activación de diversos tipos (ERPs, oscilaciones, ruido), y proyectar la actividad resultante al cuero cabelludo mediante modelos de leadfield.

SEREEGA soporta cinco modelos de cabeza diferentes en su versión inicial, entre los cuales el modelo NY Head es el de mayor resolución anatómica. El flujo de trabajo típico en SEREEGA consiste en: cargar un leadfield, definir las fuentes seleccionando posiciones del modelo cortical, crear clases de activación (con parámetros de amplitud, latencia, ancho y desviaciones

aleatorias para la variabilidad inter-ensayo), ensamblar los componentes y generar las épocas de datos simulados. La función `generate_scalpdata` aplica internamente la ecuación del problema directo ($\mathbf{V} = \mathbf{L} \cdot \mathbf{Q}$) para cada muestra temporal.

Una limitación documentada de SEREEGA es que su dependencia del ecosistema MATLAB implica requisitos de licenciamiento propietario y dificulta la integración directa con las librerías de aprendizaje profundo modernas, que en su mayoría operan en Python (PyTorch, TensorFlow). Además, la función `lf_get_source_nearest` restringe las posiciones de las fuentes a las 74,382 ubicaciones precalculadas del *leadfield*, impidiendo la colocación de dipolos en coordenadas arbitrarias del espacio MNI.

2.5.3. MNE-Python

MNE-Python es un paquete de software de código abierto para el análisis de datos de magnetoencefalografía (MEG) y electroencefalografía (EEG), implementado íntegramente en Python. Fue desarrollado inicialmente por Gramfort et al. (2013) y ha evolucionado hasta convertirse en uno de los ecosistemas más completos para el procesamiento de señales neurofisiológicas [Gramfort et al., 2013, Gramfort et al., 2014]. El paquete cubre el pipeline completo de análisis: preprocesamiento, modelado directo (*forward modeling*), localización de fuentes, análisis estadístico y estimación de conectividad funcional.

Para la simulación de señales EEG, MNE-Python ofrece la construcción explícita del modelo directo a partir de tres componentes: el espacio de fuentes (*source space*), la solución BEM del modelo de cabeza y la transformación de coordenadas entre el espacio del sujeto y el espacio de los sensores. A diferencia de SEREEGA, donde el *leadfield* se carga como una única matriz precalculada, MNE-Python ensambla el modelo directo paso a paso mediante las funciones `mne.setup_source_space`, `mne.read_bem_solution` y `mne.make_forward_solution`. Esta modularidad permite mayor control sobre cada etapa del proceso, pero también introduce una mayor complejidad procedimental.

Una ventaja fundamental de MNE-Python para los objetivos de esta memoria es su integración nativa con el ecosistema Python científico. Los datos generados se almacenan como estructuras de MNE (`Epochs`, `Evoked`) que son directamente convertibles a arreglos NumPy mediante el método `.get_data()`, lo que facilita la interfaz con librerías de aprendizaje automático como `scikit-learn`, `PyTorch` o `TensorFlow` sin necesidad de pasos de conversión intermedios.

2.6. Generación de señales sintéticas: conceptos clave

2.6.1. Modelado del componente P300 como función gaussiana

En la simulación paramétrica de potenciales evocados, la forma de onda temporal del P300 se aproxima comúnmente mediante una función gaussiana:

$$s(t) = A \cdot \exp\left(-\frac{(t - t_0)^2}{2\sigma^2}\right) \quad (4)$$

donde A es la amplitud máxima, t_0 es la latencia del máximo (centro temporal), y σ controla el ancho de la campana, determinando la duración del componente. Esta aproximación captura las propiedades esenciales del P300: polaridad positiva, latencia definida alrededor de 300 ms, y perfil temporal suave. Si bien la morfología real del P300 en un ensayo individual puede presentar asimetrías y múltiples subcomponentes, la gaussiana es la aproximación estándar adoptada tanto por SEREEGA [Krol *et al.*, 2018] como en la literatura general de simulación EEG.

La variabilidad inter-ensayo, característica fundamental de los datos empíricos, se introduce mediante perturbaciones estocásticas de los parámetros de la gaussiana: *jitter* de amplitud (variación aleatoria de A en cada ensayo, típicamente $\pm 20\%$) y *jitter* de latencia (desplazamiento temporal aleatorio de t_0 , típicamente ± 20 ms). Estas perturbaciones simulan las fluctuaciones naturales del estado cognitivo del sujeto entre ensayos consecutivos.

2.6.2. Ruido de fondo: el espectro $1/f$ y la relación señal-ruido

El ruido de fondo en una simulación EEG debe reproducir las propiedades espectrales del EEG real. Como se describió anteriormente, la densidad espectral de potencia del EEG sigue una ley $1/f^\alpha$ con $\alpha \approx 1$ (ruido rosa o *pink noise*). La generación algorítmica de este ruido se realiza típicamente en el dominio frecuencial: se genera un vector de ruido blanco (distribución uniforme de energía en todas las frecuencias) mediante un generador de números aleatorios, se transforma al dominio frecuencial mediante la Transformada Rápida de Fourier (FFT), se pondera cada componente frecuencial por $1/\sqrt{f}$ para obtener la pendiente $1/f$ deseada, y se retorna al dominio temporal mediante la FFT inversa.

La proporción entre la señal útil (el P300) y el ruido de fondo se cuantifica mediante la relación señal-ruido (SNR, *Signal-to-Noise Ratio*), expresada en decibelios (dB):

$$\text{SNR}_{\text{dB}} = 10 \cdot \log_{10}\left(\frac{P_{\text{señal}}}{P_{\text{ruido}}}\right) \quad (5)$$

donde $P_{\text{señal}}$ y P_{ruido} son las potencias de la señal y el ruido, respectivamente. En registros EEG reales, la SNR del P300 en un ensayo individual es extremadamente baja (valores negativos en dB), lo que hace necesario el promediado de múltiples ensayos para extraer la señal. En la experimentación de esta memoria se utilizó un SNR de 5 dB, un valor que permite observar el componente en el ERP promediado de 100 ensayos, manteniendo un nivel de ruido desafiante pero manejable.

CAPÍTULO 3

PROPUESTA: METODOLOGÍA Y DISEÑO EXPERIMENTAL

3.1. Parámetros Comunes de la Simulación

El diseño experimental de esta memoria se estructura como un estudio comparativo controlado en el que tres modelos de propagación volumétrica de distinta complejidad generan datos sintéticos del componente P300 a partir de los mismos parámetros de entrada. Para garantizar que las diferencias observadas entre los datos generados por cada modelo sean atribuibles exclusivamente al mecanismo de propagación y no a variaciones en las condiciones iniciales, se definió un conjunto unificado de parámetros que permanece idéntico en los tres enfoques: el montaje de electrodos, las fuentes dipolares, las formas de onda temporales, el modelo de ruido de fondo y la variabilidad inter-ensayo. Esta sección describe cada uno de estos componentes comunes. El realismo de los datos generados por cada modelo se evaluó posteriormente de forma cuantitativa, contrastándolos contra registros empíricos mediante un conjunto de métricas definidas en la Sección 3.3.3, que cuantifican la similitud entre las señales sintéticas y reales tanto en su forma temporal como en su distribución espacial sobre el cuero cabelludo.

3.1.1. Montaje de electrodos

Se utilizó un montaje de 19 canales correspondiente al Sistema Internacional 10-20, configurado en los tres ecosistemas de simulación (MATLAB/EEGLAB, MATLAB/SEREEGA y Python/MNE-Python) a partir de las coordenadas tridimensionales del estándar internacional. Los 19 electrodos cubren las regiones frontopolares (Fp1, Fp2), frontales (F7, F3, Fz, F4, F8), temporales (T7, T8), centrales (C3, Cz, C4), parietales (P7, P3, Pz, P4, P8) y occipitales (O1, O2). La frecuencia de muestreo se fijó en 256 Hz y cada época comprende una ventana temporal de -200 a $+800$ ms respecto al estímulo (256 muestras). Se verificó visualmente que el corregistro espacial de los electrodos fuera consistente entre los tres ecosistemas, tanto en proyección bidimensional como en su posicionamiento sobre modelos volumétricos tridimensionales.

3.1.2. Localización anatómica de las fuentes dipolares

El componente P300 es un potencial evocado endógeno cuya generación involucra una red distribuida de regiones corticales. La literatura neurocientífica, sustentada en estudios de localización de fuentes, registros intracorticales y estudios de lesión, identifica como generadores dominantes del subcomponente P3b la corteza parietal medial y la corteza cingulada

posterior [Polich, 2007]. Estas dos regiones fueron seleccionadas como fuentes dipolares para la simulación, ya que el P3b es el subcomponente más relevante para las aplicaciones de Interfaces Cerebro-Computadora basadas en el paradigma *oddball*.

Ambas fuentes se definieron como dipolos de corriente equivalentes en el espacio MNI (Montreal Neurological Institute), donde el eje X representa la lateralidad, el eje Y la dirección anteroposterior y el eje Z la dirección inferosuperior, todos en milímetros respecto a la comisura anterior.

La **primera fuente** (corteza parietal medial) se ubicó en $[0; -60; 40]$ mm, sobre la línea media sagital, 60 mm posterior a la comisura anterior y 40 mm por encima del plano AC-PC, cercana a la superficie cortical directamente debajo del electrodo Pz. Su vector de orientación $\mathbf{m}_1 = [0; 0,3; 1]$ es predominantemente radial, consistente con la orientación de las columnas de neuronas piramidales en esta región. La componente menor en Y refleja la ligera curvatura de la corteza parietal medial hacia la fisura interhemisférica.

La **segunda fuente** (corteza cingulada posterior) se ubicó en $[0; -45; 25]$ mm, más anterior y considerablemente más profunda que la fuente parietal, reflejando la posición anatómica de esta estructura enterrada en el surco cingulado. Su orientación $\mathbf{m}_2 = [0; 0,5; 0,8]$ es más oblicua, consecuencia de la geometría casi vertical del surco cingulado en el plano sagital. Esta diferencia de orientación produce una distribución de potencial más dispersa en el cuero cabelludo, con polaridades invertidas entre las regiones anterior y posterior.

La Figura 2 muestra la proyección de ambas fuentes sobre la representación bidimensional del cuero cabelludo, junto con sus parámetros característicos.




Figura 2: Proyección de las fuentes dipolares sobre el cuero cabelludo. Estrella verde: fuente parietal (Pz). Estrella rosa: fuente cingulada (entre Cz y Pz). Se indican las coordenadas MNI, orientaciones y parámetros temporales de cada fuente.

3.1.3. Forma de onda del componente P300

La actividad temporal de cada fuente se modeló como una función gaussiana, una aproximación estándar en la literatura de simulación de EEG que captura las propiedades fundamentales del P300: una deflexión positiva suave, una latencia definida y un ancho temporal controlable [Krol *et al.*, 2018]. La expresión utilizada es:

$$w(t) = A \cdot \exp\left(-\frac{(t - t_0)^2}{2\sigma^2}\right) \quad (6)$$

donde A es la amplitud máxima, t_0 la latencia del máximo y σ la desviación estándar temporal. Para la fuente parietal se utilizaron $A_1 = 10$, $t_{0,1} = 300$ ms y $\sigma_1 = 50$ ms, y para la fuente cingulada $A_2 = 6$, $t_{0,2} = 280$ ms y $\sigma_2 = 60$ ms. Esta configuración produce un generador cingulado de menor amplitud (60 % del parietal), con latencia anterior (20 ms de precedencia) y mayor dispersión temporal, consistente con la evidencia electrofisiológica que sugiere que la contribución cingulada precede ligeramente al componente parietal [Polich, 2007]. La señal combinada se escaló por un factor de 5 para situar la amplitud resultante en el rango de 5 a 15 μ V, representativo de registros empíricos con referencia promedio.

La Figura 3 presenta las formas de onda individuales y su superposición temporal. La **señal combinada** (línea punteada) corresponde a la suma punto a punto de las dos gaussianas e ilustra la forma de onda resultante del P300 cuando ambos generadores contribuyen simultáneamente. Cabe precisar que cada fuente se propaga al cuero cabelludo con su propia gaussiana de forma independiente; la suma de sus contribuciones no se impone como entrada, sino que emerge en cada electrodo por superposición lineal de los potenciales, de acuerdo con la linealidad del problema directo. La señal combinada se muestra, por tanto, como referencia visual de la morfología temporal conjunta esperada del componente P300.




Figura 3: Formas de onda gaussianas de las fuentes dipolares: parietal (verde, $t_0 = 300$ ms) y cingulado (rosa, $t_0 = 280$ ms). La línea punteada muestra la señal combinada, es decir, la suma de ambas gaussianas, que ilustra la morfología temporal conjunta del P300 resultante de la contribución de los dos generadores. La zona rosada delimita la ventana P300.

3.1.4. Modelo de ruido y variabilidad inter-ensayo

Para cada una de las 100 épocas simuladas, se generó una instancia independiente de ruido de fondo con estructura espectral $1/f$ (ruido rosa), característica universal de las señales EEG cuyo espectro de potencia decae según $S(f) \propto 1/f^\beta$ con β entre 1 y 2. El procedimiento consiste en generar ruido blanco gaussiano, transformarlo al dominio frecuencial mediante FFT, aplicar un filtro de amplitud $H(f) = 1/\sqrt{f}$ (eliminando la componente DC), y retornar al dominio temporal. La amplitud del ruido se calibró para obtener una relación señal-ruido de 5 dB mediante:

$$A_{\text{ruido}} = \sqrt{\frac{P_{\text{señal}}}{10^{SNR/10}}} \quad (7)$$

lo que implica que la potencia de la señal es aproximadamente 3.16 veces mayor que la del ruido, proporción que permite que el P300 sea discernible en el promedio pero quede parcialmente enmascarado en épocas individuales, comportamiento consistente con registros empíricos. El ruido se genera independientemente para cada canal y época, sin correlación espacial entre electrodos.

Adicionalmente, se introdujo variabilidad inter-ensayo mediante dos perturbaciones aplicadas independientemente a cada época: un factor multiplicativo de amplitud uniformemente distribuido entre 0.8 y 1.2 ($\pm 20\%$), y un desplazamiento temporal de latencia de ± 20 ms (± 5 muestras a 256 Hz). Estos rangos son consistentes con la variabilidad del P300 reportada en la literatura, donde la desviación estándar de la amplitud se sitúa entre 15 % y 30 %, y la de

la latencia entre 10 y 40 ms.

La Figura 4 ilustra el efecto combinado del ruido y la variabilidad sobre el canal Pz, mostrando cómo el componente P300 emerge del ruido tras el promediado coherente de 100 épocas. La Figura 5 verifica que el ruido generado presenta la pendiente espectral $1/f$ esperada.




Figura 4: Superposición de 20 épocas individuales (trazas grises) y ERP promedio (curva roja, $n = 100$) del canal Pz. El ruido $1/f$ y el jitter de amplitud ($\pm 20\%$) y latencia (± 20 ms) introducen variabilidad sustancial entre ensayos, mientras que el promediado coherente permite la emergencia del componente P300.




Figura 5: Espectro de potencia del ruido generado. El ruido rosa (rojo) presenta la pendiente $1/f$ esperada con concentración de energía en frecuencias bajas, mientras que el ruido blanco (azul) mantiene distribución plana. La línea punteada indica la pendiente teórica $1/f$.

Es importante señalar que este modelo de ruido, si bien captura la estructura espectral $1/f$ y la variabilidad inter-ensayo básica, no incorpora fenómenos presentes en registros reales co-

mo artefactos oculares, contaminación muscular, interferencia de línea eléctrica, correlación espacial del ruido entre canales vecinos, ni degradación progresiva por fatiga cognitiva. Estas limitaciones serán consideradas en la validación estadística contra datos reales (Sección 3.3).

3.1.5. Resumen de parámetros de simulación

La Tabla 1 consolida el conjunto de parámetros de entrada empleados en la generación de los datos sintéticos. Estos valores permanecen idénticos en los tres modelos de propagación, de modo que cualquier diferencia observada en los datos resultantes es atribuible exclusivamente al mecanismo de propagación volumétrica y no a las condiciones iniciales de la simulación.

Tabla 1: Parámetros comunes de la simulación, idénticos en los tres modelos de propagación.

Parámetro	Valor	Símbolo / unidad
<i>Montaje y muestreo</i>		
Canales	19 (Sistema Internacional 10-20)	—
Frecuencia de muestreo	256	Hz
Ventana temporal	−200 a +800 (256 muestras)	ms
Épocas por modelo	100	—
<i>Fuente 1 – parietal medial</i>		
Posición (MNI)	[0; −60; 40]	mm
Orientación	[0; 0,3; 1]	$\mathbf{m}_1$
Amplitud	10	A_1
Latencia del máximo	300	$t_{0,1}$ (ms)
Dispersión temporal	50	σ_1 (ms)
<i>Fuente 2 – cingulada posterior</i>		
Posición (MNI)	[0; −45; 25]	mm
Orientación	[0; 0,5; 0,8]	$\mathbf{m}_2$
Amplitud	6 (60 % de la parietal)	A_2
Latencia del máximo	280	$t_{0,2}$ (ms)
Dispersión temporal	60	σ_2 (ms)
<i>Forma de onda y escala</i>		
Función temporal	Gaussiana (Ec. (6))	—
Factor de escala de la señal	5	—
Rango de amplitud resultante	5–15	μV
<i>Ruido y variabilidad inter-ensayo</i>		
Tipo de ruido	$1/f$ (rosa)	—
Relación señal-ruido (SNR)	5	dB
Jitter de amplitud	± 20	%
Jitter de latencia	± 20 (± 5 muestras)	ms

3.2. Tres Modelos de Propagación Volumétrica

El problema directo (*forward problem*) en electroencefalografía consiste en calcular el potencial eléctrico que una configuración conocida de fuentes cerebrales produce en cada electrodo del cuero cabelludo. Matemáticamente se expresa como $\mathbf{V} = \mathbf{L} \cdot \mathbf{J}$, donde $\mathbf{V}$ es el vector de

potenciales en los electrodos, $\mathbf{L}$ la matriz de *leadfield* y $\mathbf{J}$ el vector de momentos dipolares. La calidad de esta resolución depende del modelo de cabeza utilizado para construir $\mathbf{L}$, ya que la señal eléctrica debe atravesar tejidos con conductividades marcadamente diferentes: cerebro (~ 0.33 S/m), líquido cefalorraquídeo (~ 1.79 S/m), cráneo (~ 0.0042 S/m) y cuero cabelludo (~ 0.33 S/m). El cráneo, con una conductividad aproximadamente 80 veces menor que el tejido cerebral, produce una atenuación significativa y dispersión espacial de las corrientes.

Con el objetivo de evaluar empíricamente el impacto de esta elección metodológica, se implementaron tres enfoques de complejidad creciente. Los tres utilizan las mismas fuentes, formas de onda, parámetros de ruido y montaje de electrodos descritos en la Sección anterior, de modo que la única variable independiente es el modelo de propagación.

3.2.1. Modelo 1: Dipolo en esfera conductora homogénea

El primer modelo, implementado en MATLAB, emplea una solución analítica del potencial generado por un dipolo dentro de una esfera conductora de conductividad uniforme. La cabeza se aproxima como un volumen esférico isotrópico sin distinción entre tejidos:

$$V_i = \frac{(\mathbf{r}_i - \mathbf{r}_d) \cdot \mathbf{m}}{|\mathbf{r}_i - \mathbf{r}_d|^3} \quad (8)$$

donde $\mathbf{r}_i$ es la posición del electrodo, $\mathbf{r}_d$ la posición del dipolo y $\mathbf{m}$ su momento dipolar. Esta formulación permite colocar fuentes en cualquier coordenada sin restricciones y su cálculo es instantáneo, pero al asumir conductividad homogénea no modela la atenuación y dispersión que introduce el cráneo, lo que tiende a sobreestimar la focalización de las fuentes y a subestimar la dispersión topográfica.

3.2.2. Modelo 2: Leadfield BEM del modelo NY Head (SEREEGA)

El segundo modelo, implementado mediante la librería SEREEGA en MATLAB, utiliza la matriz de *leadfield* precalculada del modelo NY Head. Este modelo fue construido mediante el Método de Elementos de Frontera (BEM), que discretiza las interfaces entre tejidos como mallas triangulares y resuelve las ecuaciones de Maxwell en cada frontera. El modelo anatómico, derivado de imágenes de resonancia magnética del proyecto ICBM, modela explícitamente tres superficies de frontera (cerebro-LCR, LCR-cráneo y cráneo-cuero cabelludo) con conductividades diferenciadas.

La matriz de *leadfield* contiene 74 382 posiciones de fuentes distribuidas sobre la superficie cortical, con 228 electrodos del sistema 10-05. Las fuentes objetivo fueron mapeadas a las posiciones más cercanas del *leadfield*: la fuente parietal [0; -60; 40] se ma-

peó a $[-2,6; -59,4; 41,9]$ mm (distancia: 3,3 mm) y la cingulada $[0; -45; 25]$ a $[-2,7; -46,3; 23,6]$ mm (distancia: 3,3 mm), ambas dentro del margen de error típico de localización de fuentes en EEG (5–15 mm). De los 228 canales disponibles, se extrajeron los 19 correspondientes al montaje 10-20. La proyección al cuero cabelludo se obtiene como:

$$V_i = \mathbf{L}_{i,j} \cdot \hat{\mathbf{m}} \quad (9)$$

3.2.3. Modelo 3: fsaverage BEM (MNE-Python)

El tercer enfoque utiliza el atlas cerebral **fsaverage** de FreeSurfer, un promedio poblacional derivado de 40 sujetos adultos sanos, con una solución BEM de tres capas precalculada (5,120 triángulos por superficie). A diferencia del NY Head (basado en un único sujeto), fsaverage representa la variabilidad inter-sujeto pero es menos detallado anatómicamente. A diferencia de SEREEGA, MNE-Python permite colocar las fuentes en las coordenadas exactas sin necesidad de mapearlas a vértices predefinidos.

La inclusión de este tercer enfoque responde además a una motivación práctica: la generación nativa en Python permite que los datos sean procesados directamente con las librerías científicas del mismo ecosistema sin requerir conversiones entre formatos.

La Tabla 2 resume las diferencias entre los tres enfoques.

Tabla 2: Comparación de los tres modelos de propagación volumétrica.

Característica	Esfera	NY Head	fsaverage
Geometría	Esférica	Anatómica (1 sujeto)	Anatómica (promedio)
Capas de tejido	1 (homogénea)	3 (BEM)	3 (BEM)
Método de cálculo	Analítico	Numérico (precalc.)	Numérico (en línea)
Fuentes corticales	Posición libre	74,382 vértices	Posición libre
Ecosistema	MATLAB	MATLAB / SEREEGA	Python / MNE
Origen anatómico	—	ICBM (1 RM)	FreeSurfer (40 sujetos)

3.3. Validación Estadística contra Datos Reales

Para evaluar cuantitativamente el realismo de los datos sintéticos generados por los tres modelos de propagación, se realizó una comparación estadística contra registros empíricos de P300 provenientes de un dataset público de referencia.

3.3.1. Dataset de referencia

Se utilizó el Dataset II del BCI Competition III [Blankertz *et al.*, 2006], proporcionado por el Wadsworth Center (NYS Department of Health). Este dataset contiene registros de EEG de 2 sujetos realizando una tarea de P300 Speller con paradigma *oddball* (matriz 6×6), capturados con 64 canales del sistema extendido 10-20 a 240 Hz, filtrados entre 0.1 y 60 Hz. Para la presente validación se utilizaron los datos de entrenamiento del Sujeto A, que comprenden 85 épocas de caracteres con 180 intensificaciones cada una (15 repeticiones $\times$ 12 filas/columnas), de las cuales 2 de cada 12 corresponden a estímulos target (con P300) y las 10 restantes a estímulos non-target (sin P300).

De los 64 canales disponibles, se extrajeron los 19 correspondientes al montaje del Sistema Internacional 10-20 utilizado en las simulaciones, garantizando la comparabilidad directa entre los vectores de amplitud de los datos reales y sintéticos.

3.3.2. Preprocesamiento: aislamiento del componente P300

Dado que las simulaciones modelan exclusivamente el componente P300 sin incluir los potenciales evocados tempranos (N100, N200, P200) que están presentes en cualquier registro empírico, una comparación directa entre el ERP target real y los ERPs sintéticos estaría contaminada por componentes que los simuladores no pretenden reproducir. Para garantizar una comparación justa, se calculó la **onda diferencia** (ERP target – ERP non-target), un procedimiento estándar en la literatura de P300-BCI que aísla el componente P300 eliminando los componentes evocados comunes a ambas condiciones [Farwell y Donchin, 1988]. Formalmente, para cada canal c y muestra temporal t , la onda diferencia se define como:

$$\text{ERP}_{\Delta}(c, t) = \text{ERP}_{\text{target}}(c, t) - \text{ERP}_{\text{non-target}}(c, t) \quad (10)$$

donde $\text{ERP}_{\text{target}}$ y $\text{ERP}_{\text{non-target}}$ son los potenciales promedio de las condiciones *target* y *non-target*, respectivamente. Dado que los componentes evocados tempranos (N100, N200, P200) son comunes a ambas condiciones, su sustracción los cancela y aísla la contribución diferencial del P300. Este procedimiento se aplicó tanto a nivel del ERP promedio como a nivel de épocas individuales (restando el ERP non-target promedio a cada época target individual), preservando la variabilidad inter-ensayo necesaria para las comparaciones distribucionales.

3.3.3. Métricas de comparación

La comparación entre los datos sintéticos y los datos reales se realizó en tres dimensiones complementarias: morfología temporal, distribución topográfica y correlación por canal.

La **morfología temporal** se evaluó superponiendo los ERPs normalizados (escalados al rango $[0, 1]$) de los tres modelos sintéticos con el ERP real en los canales Pz y Cz, que son los electrodos donde el P300 presenta su máxima amplitud. La normalización permite comparar la forma de onda independientemente de la amplitud absoluta, que difiere entre los datos reales (del orden de $5\text{--}20 \mu\text{V}$) y los sintéticos (del orden de $60\text{--}80 \mu\text{V}$) debido a las diferencias en el factor de escala y las unidades del amplificador.

La **distribución topográfica** se evaluó extrayendo el vector de 19 amplitudes normalizadas al instante del máximo P300 del ERP real (336 ms), y comparándolo con los vectores equivalentes de cada modelo sintético. La similitud entre el vector topográfico real y cada vector sintético se cuantificó mediante dos métricas complementarias: el coeficiente de correlación de Pearson, que mide la similitud del patrón espacial con independencia de la escala, y el error cuadrático medio (RMSE) normalizado, que mide la diferencia absoluta punto a punto entre ambos vectores.

El coeficiente de correlación de Pearson entre dos vectores $\mathbf{x}$ e $\mathbf{y}$ de longitud N se define como:

$$r(\mathbf{x}, \mathbf{y}) = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}} \quad (11)$$

donde $\bar{x}$ e $\bar{y}$ son las medias de cada vector. El coeficiente toma valores en $[-1, 1]$: un valor de $+1$ indica una similitud de forma perfecta, 0 ausencia de relación lineal, y valores negativos una variación en sentido opuesto. Por su parte, el RMSE entre los vectores topográficos normalizados se define como:

$$\text{RMSE}(\mathbf{x}, \mathbf{y}) = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (12)$$

donde $N = 19$ es el número de canales. A diferencia de la correlación, un RMSE menor indica mayor cercanía entre las distribuciones, siendo 0 una coincidencia exacta. Dado que las amplitudes absolutas difieren entre los datos reales y sintéticos, ambos vectores se normalizaron previamente dividiéndolos por su valor absoluto máximo, de modo que las métricas reflejen la distribución relativa de la señal y no su escala.

La **correlación de forma por canal** se calculó aplicando el mismo coeficiente de correlación de Pearson de la Ecuación (11) entre la serie temporal completa del ERP real y el ERP sintético en cada uno de los 19 canales, proporcionando un perfil espacial de la similitud morfológica.

CAPÍTULO 4

RESULTADOS Y ANÁLISIS

Este capítulo presenta los resultados obtenidos a partir de la metodología descrita en el capítulo anterior y su análisis. En primer lugar, se exponen las distribuciones espaciales y temporales del componente P300 generadas por cada uno de los tres modelos de propagación, evidenciando las diferencias sistemáticas que introduce el modelo de cabeza. A continuación, se contrastan cuantitativamente los datos sintéticos contra registros empíricos de P300, aplicando las métricas de comparación definidas en la Sección 3.3.3. Finalmente, se sintetizan las principales brechas de realismo identificadas, que orientan las líneas de mejora del trabajo.

4.1. Distribuciones del P300 según el Modelo de Propagación

Una vez definidos los tres modelos de propagación, se procedió a generar los datos sintéticos del componente P300 utilizando en cada caso las mismas fuentes dipolares, formas de onda gaussianas, modelo de ruido $1/f$ y variabilidad inter-ensayo descritos en la Sección 3.1. Para cada enfoque se generaron 100 épocas de 256 muestras (1 segundo a 256 Hz) en los 19 canales del montaje 10-20, produciendo tres conjuntos de datos tridimensionales de dimensiones $[19 \times 256 \times 100]$ (canales $\times$ muestras $\times$ épocas). Las siguientes subsecciones presentan las distribuciones topográficas y temporales obtenidas, con el propósito de evidenciar las diferencias que introduce cada modelo de propagación sobre los datos sintéticos antes de proceder a su validación contra registros empíricos.

La Figura 6 presenta las topografías del potencial P300 a 300 ms post-estímulo obtenidas con los modelos de esfera y NY Head, utilizando una escala de color común en la que los tonos rojos representan amplitudes positivas (máximos del potencial) y los azules amplitudes negativas (mínimos o inversiones de polaridad), expresadas en microvoltios. El modelo de esfera produce una distribución focalizada en la zona parietal posterior (máximo $74,5 \mu V$ en Pz), mientras que el modelo NY Head genera una distribución más amplia con el máximo desplazado hacia la región centro-parietal ($75,5 \mu V$). Esta divergencia se explica porque la geometría real del cráneo no es esférica ni uniforme en grosor, y porque las fuentes encontradas en el NY Head presentan una leve lateralización ($X = -2,6 \text{ mm}$) que, combinada con la orientación cortical local, produce la asimetría topográfica observada.




Figura 6: Comparación topográfica del P300 a 300 ms bajo los modelos de esfera homogénea (izquierda, máximo $74,5 \mu V$) y NY Head BEM (derecha, máximo $75,5 \mu V$), con escala de color común: los tonos rojos indican amplitudes positivas y los azules, amplitudes negativas, en microvoltios. Las mismas fuentes dipolares producen topografías cualitativamente distintas según el modelo de cabeza.

La Figura 7 muestra la topografía del tercer modelo (fsaverage BEM), que presenta un máximo de $69.0 \mu V$ en la región centro-parietal (Cz) con una característica distintiva: una marcada inversión de polaridad en los canales occipitales (O1, O2), consecuencia directa del modelado BEM con tres capas de conductividad diferenciada aplicado sobre la geometría promedio poblacional del atlas fsaverage. Esta inversión no se reproduce ni en el modelo de Esfera ni en el NY Head con la misma intensidad.




Figura 7: Topografía del P300 a 300 ms generada con MNE-Python (fsaverage BEM). Máximo en Cz (69.0 μV) con inversión de polaridad en O1 y O2.

4.2. Comparación de las Señales Generadas

Las topografías presentadas en la sección anterior ofrecen una vista espacial del P300 congelada en un instante temporal (300 ms). Para completar la caracterización de los datos sintéticos, esta sección examina la señal en el dominio temporal de manera simultánea para los 19 canales, lo que permite apreciar cómo la distribución de amplitudes se despliega a lo largo de la ventana del componente evocado.

Antes de examinar los ERPs con ruido, resulta informativo inspeccionar la señal limpia (sin ruido ni jitter) del modelo fsaverage para visualizar directamente el efecto del *leadfield* BEM sobre la propagación. La Figura 8 muestra las formas de onda en cuatro canales representativos: el máximo se localiza en Cz (71,9 μV), seguido de Pz (65,5 μV) y Fz (37,2 μV), mientras que O1 presenta una inversión de polaridad de $-50,2 \mu\text{V}$. Esta inversión, consecuencia directa del modelado BEM con tres capas de conductividad, no se obtiene con el modelo de esfera homogénea y anticipa una de las diferencias más relevantes entre los enfoques.




Figura 8: Señal limpia (sin ruido) del modelo fsaverage BEM en cuatro canales representativos (Fz, Cz, Pz, O1). Se observa la inversión de polaridad en O1, característica del modelado BEM con tres capas de conductividad.

Las Figuras 9, 10 y 11 presentan los ERPs promedio ($n = 100$ épocas) de los 19 canales para cada modelo de propagación, con codificación de color por región cerebral y ventanas temporales delimitadas para el N100 y el P300.




Figura 9: ERP promedio del modelo de esfera homogénea. El máximo del P300 se localiza en los canales parietales y occipitales (Pz, O1, O2), con atenuación progresiva hacia las regiones frontales. Los canales frontales (Fp1, Fp2, F7, F3, Fz, F4, F8) presentan deflexiones mínimas.




Figura 10: ERP promedio del modelo NY Head BEM. Comparado con la Esfera, se observa mayor activación en los canales frontales (F3, Fz, F4) y centrales (Cz), y un desplazamiento del máximo desde la región parietal-occipital hacia la centro-frontal. La distribución más amplia refleja la dispersión introducida por el modelado realista del cráneo.




Figura 11: ERP promedio del modelo fsaverage BEM (MNE-Python). Deflexiones positivas significativas en los canales frontales y centrales, e inversión de polaridad marcada en los canales occipitales (O1, O2). El máximo del ERP alcanza $70.3 \mu\text{V}$ en Cz a 294 ms.

La comparación de los tres ERPs revela diferencias sistemáticas atribuibles al modelo de propagación:

1. **Localización del máximo de amplitud.** En el modelo de Esfera, el máximo se concentra en la región parietal-occipital (Pz, O1, O2), directamente debajo de las fuentes dipolares. En el NY Head BEM, se desplaza hacia la región centro-frontal (Fz, Cz), reflejando la dispersión del cráneo modelado con conductividad realista. En el fsaverage BEM, el máximo se localiza en Cz con amplitudes frontales aún más pronunciadas.
2. **Activación frontal.** El modelo de Esfera produce deflexiones mínimas en los canales frontales. Ambos modelos BEM generan activación frontal significativa, con el fsaverage produciendo las deflexiones frontales más amplias de los tres modelos. Esto sugiere que el modelado multicapa permite que las corrientes se propaguen hacia regiones distantes de las fuentes de manera más realista.
3. **Inversión de polaridad occipital.** El fenómeno más distintivo del fsaverage es la inversión de polaridad en O1 y O2 (deflexiones negativas de hasta $-50 \mu\text{V}$ en la señal limpia), ausente en el modelo de Esfera y presente con menor intensidad en el NY Head. Esta inversión es consecuencia de la geometría específica del atlas poblacional y la orientación de las fuentes respecto a las superficies de frontera del BEM.

4. **Dispersión espacial global.** El modelo de esfera produce la distribución más focalizada (actividad concentrada en pocos canales), seguido del NY Head (distribución intermedia) y el fsaverage (distribución más amplia con participación de prácticamente todas las regiones). Esta progresión correlaciona con la complejidad creciente del modelo de cabeza.

Estos hallazgos confirman que la elección del modelo de propagación no es una decisión técnica menor, sino que altera de manera fundamental la distribución espacial y las amplitudes relativas del P300 simulado. Un modelo de esfera puede ser adecuado para estudios que solo requieran la morfología temporal del componente en un canal específico, pero resulta insuficiente cuando la distribución topográfica realista es relevante, como en estudios que requieran fidelidad espacial de la distribución del P300.

Sin embargo, las diferencias observadas entre los tres modelos son cualitativas: se puede apreciar visualmente que las distribuciones topográficas y temporales difieren, pero no es posible determinar a partir de la inspección visual cuál de ellas se asemeja más a un registro empírico real de P300. Para responder esta pregunta de manera cuantitativa y fundamentar la elección de un modelo sobre otro, la siguiente sección presenta la validación estadística de los datos sintéticos generados contra un dataset público de registros reales de P300.

4.3. Validación contra Datos Reales

Las diferencias descritas hasta aquí son cualitativas. Para fundamentar de manera cuantitativa cuál de los tres modelos reproduce con mayor fidelidad un registro empírico de P300, se aplicaron las métricas definidas en la Sección 3.3.3 sobre la onda diferencia del dataset BCI Competition III, contrastándola con los ERPs sintéticos de cada modelo.

4.3.1. Resultados de la comparación

La Figura 12 presenta la superposición de los ERPs normalizados en los canales Pz y Cz. En ambos canales, los tres modelos sintéticos capturan correctamente la deflexión positiva del P300 dentro de la ventana temporal esperada (250–450 ms), con latencias del máximo sintético (~ 345 ms) razonablemente cercanas a la del máximo real (~ 356 ms). Sin embargo, se observan dos diferencias morfológicas relevantes. En primer lugar, el P300 real presenta una forma asimétrica con subida rápida y caída lenta, mientras que los ERPs sintéticos, generados a partir de funciones gaussianas simétricas, presentan flancos de subida y bajada equivalentes. En segundo lugar, el ERP real muestra mayor amplitud relativa en el canal Cz que en Pz, comportamiento que reproducen los modelos BEM (NY Head y fsaverage) pero no el modelo de esfera, cuyo máximo se localiza en Pz.




Figura 12: Comparación de la morfología temporal del ERP en los canales Pz y Cz. Línea verde: P300 real aislado (onda diferencia, BCI Competition III). Líneas punteadas: ERPs sintéticos de los tres modelos. Todos los ERPs están normalizados al rango $[0, 1]$ para comparar forma. La zona rosada delimita la ventana P300 (250–450 ms).

La Figura 13 presenta las correlaciones de Pearson por canal entre cada modelo sintético y los datos reales. Los canales centro-parietales (Cz, Pz, P7) presentan las correlaciones más altas (0.6–0.85), indicando que los tres modelos reproducen adecuadamente la morfología temporal del P300 en las regiones donde este componente es más prominente. Los canales frontales (Fz, F3, F4) y centrales (C3, C4) muestran correlaciones moderadas (0.4–0.7). En contraste, los canales temporales (T7, T8) y laterales (F7, F8) presentan correlaciones negativas o cercanas a cero en los tres modelos, lo cual constituye una limitación estructural de la simulación con dos fuentes dipolares que no puede reproducir la actividad lateral presente en los registros reales.




Figura 13: Correlación de Pearson entre la forma del ERP sintético y el ERP real (onda diferencia) por canal, para los tres modelos de propagación. Los canales centro-parietales presentan las correlaciones más altas ($r > 0,6$), mientras que los canales temporales y laterales muestran correlaciones negativas, evidenciando las limitaciones del modelo de dos dipolos.

La Figura 14 compara la distribución topográfica normalizada al instante del máximo P300 (336 ms). El patrón topográfico real presenta su máximo en Cz con valores positivos amplios en toda la región frontal-central (Fp1, Fp2, F3, Fz, F4) y valores negativos moderados en los canales temporales (T8) y parietales laterales (P7). Los modelos BEM (NY Head y fsaverage) reproducen correctamente la localización del máximo en Cz, mientras que el modelo de esfera ubica su máximo en Pz. Sin embargo, tanto la esfera como el fsaverage producen valores negativos pronunciados en los canales occipitales (O1, O2) que no se observan con la misma intensidad en los datos reales, siendo el fsaverage el que presenta la inversión de polaridad más exagerada.




Figura 14: Distribución topográfica normalizada al instante del máximo P300 (336 ms). Los datos reales (verde) presentan máximo en Cz con distribución frontal-central amplia. NY Head y fsaverage reproducen el máximo en Cz, mientras que la esfera lo ubica en Pz. Los tres modelos sintéticos subestiman la activación frontal y producen valores negativos en la región occipital que los datos reales no presentan con la misma magnitud.

4.3.2. Diagnóstico de brechas de realismo

La validación contra datos reales permite identificar cinco brechas principales entre los datos sintéticos y los registros empíricos.

La primera brecha es la simetría temporal de la forma de onda. Los tres modelos utilizan funciones gaussianas simétricas, mientras que el P300 real presenta una asimetría característica (subida rápida, caída lenta) que refleja los procesos de activación y desactivación neuronal. Esta limitación podría abordarse reemplazando la gaussiana por funciones asimétricas como la distribución gamma o la gaussiana con sesgo (*skewed gaussian*).

La segunda brecha es la distribución topográfica frontal. Los datos reales muestran actividad positiva significativa en los canales frontopolares (Fp1, Fp2) y frontales (F3, F4, Fz) que los tres modelos subestiman considerablemente. Esto sugiere que el P300 real involucra generadores frontales adicionales que no están contemplados en el modelo de dos dipolos (parietal + cingulado).

La tercera brecha es la actividad en canales temporales y laterales. Las correlaciones negativas en T7, T8, F7 y F8 indican que la actividad registrada en estas regiones en los datos reales no puede ser explicada por dos fuentes mediales. La incorporación de fuentes dipolares adicionales en regiones temporales y frontales laterales sería necesaria para mejorar la fidelidad en estos canales.

La cuarta brecha es la estructura del ruido de fondo. El análisis espectral de la ventana pre-

estímulo reveló que el ruido real presenta una pendiente $1/f$ más pronunciada en las frecuencias bajas, un máximo de interferencia de línea eléctrica a 60 Hz, y energía sustancialmente menor en las frecuencias altas (> 80 Hz) en comparación con el ruido simulado. Además, el ruido real presenta correlación espacial entre canales vecinos que el modelo actual, con ruido independiente por canal, no reproduce.

La quinta brecha es la variabilidad inter-ensayo. Las distribuciones de amplitud normalizada del P300 por época muestran que los datos sintéticos presentan una dispersión ($\sigma \approx 0,04-0,08$) considerablemente menor que los datos reales ($\sigma \approx 0,13$), indicando que el jitter paramétrico de $\pm 20\%$ en amplitud y ± 20 ms en latencia es insuficiente para reproducir la variabilidad biológica genuina, que incluye fluctuaciones de atención, fatiga cognitiva y artefactos residuales.

4.4. Síntesis del Análisis

El conjunto de resultados confirma que la elección del modelo de propagación condiciona de forma determinante la distribución topográfica y las amplitudes relativas del P300 simulado. La validación cuantitativa muestra que los dos modelos BEM (NY Head y fsaverage) reproducen correctamente la localización del máximo en Cz observada en los datos reales, ventaja que el modelo de esfera no alcanza al situar su máximo en Pz. No obstante, los tres modelos comparten limitaciones estructurales comunes derivadas del uso de dos fuentes dipolares mediales y de funciones gaussianas simétricas: subestimación de la actividad frontal, correlaciones negativas en canales temporales y laterales, simetría temporal de la forma de onda, y variabilidad inter-ensayo reducida. Las cinco brechas identificadas constituyen, por tanto, el punto de partida natural para las líneas de trabajo futuro discutidas en el capítulo de conclusiones.

CAPÍTULO 5

CONCLUSIONES Y TRABAJO FUTURO

5.1. Conclusiones

Este trabajo abordó el estudio comparativo de tres modelos de propagación volumétrica, el dipolo en esfera conductora homogénea, el *leadfield* BEM del modelo NY Head y el BEM del atlas poblacional fsaverage, para la simulación del componente P300 de los potenciales relacionados con eventos. A partir de un conjunto unificado de parámetros de entrada, idéntico en los tres enfoques, se generaron datos sintéticos cuyas diferencias resultan atribuibles exclusivamente al mecanismo de propagación, y se evaluó su realismo contrastándolos cuantitativamente contra registros empíricos del Dataset II del BCI Competition III.

El principal hallazgo es que la elección del modelo de propagación no constituye una decisión técnica menor, sino que altera de forma fundamental la distribución espacial y las amplitudes relativas del P300 simulado. El modelo de esfera homogénea produce una distribución focalizada con el máximo en la región parietal-occipital, directamente bajo las fuentes dipolares, y subestima la dispersión de las corrientes. Los modelos BEM, al incorporar tres capas de conductividad diferenciada, generan una distribución más amplia con desplazamiento del máximo hacia la región centro-frontal, fenómeno coherente con la atenuación y dispersión que introduce el cráneo en un conductor de volumen realista.

La validación estadística contra datos reales permitió fundamentar de manera objetiva la comparación entre modelos. Los dos modelos BEM reproducen correctamente la localización del máximo del P300 en el canal Cz, característica observada en los registros empíricos, mientras que el modelo de esfera la sitúa erróneamente en Pz. Las correlaciones de forma por canal más altas se concentran en las regiones centro-parietales, donde el P300 es más prominente, confirmando que los tres modelos capturan adecuadamente la morfología temporal del componente en las zonas de mayor relevancia electrofisiológica.

Respecto a los objetivos formulados, el trabajo logró implementar y comparar de forma controlada los tres enfoques de propagación, cuantificar sus diferencias mediante métricas objetivas de morfología temporal y distribución topográfica, y establecer un procedimiento de validación reproducible contra datos empíricos. Estos resultados proporcionan un criterio fundamentado para la selección del modelo de propagación en función de las necesidades del estudio: un modelo de esfera puede resultar suficiente cuando solo se requiere la morfología temporal del componente en un canal específico, mientras que un modelo BEM es necesario cuando la fidelidad espacial de la distribución topográfica es relevante.

5.1.1. Implicancias prácticas y teóricas

Los resultados poseen consecuencias directas para la generación de datos sintéticos orientada al entrenamiento de clasificadores en interfaces cerebro-computadora. El propósito último de un simulador de P300 en este contexto es producir ejemplos de aumento de datos que mejoren la capacidad de generalización de modelos de aprendizaje profundo entrenados sobre cohortes empíricas reducidas. La fidelidad topográfica resulta determinante para este fin, dado que las arquitecturas convolucionales y los mecanismos de atención que operan sobre representaciones multicanal aprenden patrones espaciales además de temporales. Un simulador que ubica erróneamente el máximo del componente, como ocurre con el modelo de esfera al situarlo en Pz en lugar de Cz, induciría en el clasificador una representación espacial sesgada que degradaría su desempeño al enfrentarse a registros reales. La superioridad espacial de los modelos BEM adquiere así un valor instrumental concreto y no meramente descriptivo.

La elección entre los dos modelos BEM evaluados depende del compromiso entre fidelidad anatómica y representatividad poblacional. El NY Head, derivado de la anatomía de un atlas individual de alta resolución, preserva detalles estructurales finos como asimetrías hemisféricas y grosor craneal variable, lo que produce topografías de alta fidelidad pero potencialmente sesgadas hacia particularidades anatómicas no generalizables. El fsaverage, al promediar 40 sujetos, suaviza estos detalles y genera distribuciones más representativas de la población general, a costa de una menor focalización. Para una aplicación de aumento de datos cuyo objetivo es la generalización inter-sujeto, la representatividad poblacional del fsaverage constituye una propiedad deseable, mientras que el NY Head resulta preferible cuando el estudio busca reproducir la anatomía de un individuo específico.

En el plano teórico, los hallazgos confirman empíricamente la sensibilidad del potencial de superficie a la geometría del conductor de volumen, en particular para fuentes profundas como el cíngulo posterior. La inversión de polaridad observada en los canales occipitales del modelo fsaverage, ausente en el modelo de esfera y de menor intensidad en el NY Head, evidencia que la orientación de las fuentes respecto a las superficies de frontera del BEM determina fenómenos de polaridad que ningún modelo analítico simplificado puede anticipar. Este resultado refuerza la noción de que el problema directo en EEG no admite aproximaciones geométricas sin consecuencias topográficas medibles.

5.1.2. Evaluación comparativa de las plataformas

El desarrollo de los tres modelos en dos ecosistemas tecnológicos distintos permitió contrastar las plataformas SEREEGA, sobre MATLAB, y MNE-Python en condiciones equivalentes de simulación. Ambas reproducen el problema directo a partir de la misma formulación lineal entre fuentes y sensores, pero difieren sustancialmente en su arquitectura, flexibilidad y modelo de integración con flujos de trabajo posteriores.

SEREEGA ofrece un flujo de trabajo modular y orientado explícitamente a la generación de actividad EEG con *ground truth* conocido, con una abstracción de alto nivel que simplifica la definición de fuentes y clases de activación. Su principal restricción operativa radica en que las fuentes deben mapearse a las posiciones precalculadas del *leadfield* del NY Head, lo que impide la colocación de dipolos en coordenadas arbitrarias del espacio MNI y obliga a una aproximación a la posición más cercana. En la experimentación, este mapeo introdujo desplazamientos del orden de 3 mm respecto a las coordenadas objetivo, una magnitud dentro del margen de error típico de localización de fuentes en EEG, pero que documenta una pérdida de control sobre la posición exacta del generador. Su dependencia del entorno propietario MATLAB y la dificultad de interoperar con las librerías de aprendizaje profundo, mayoritariamente implementadas en Python, constituyen limitaciones relevantes para un flujo de aumento de datos orientado a redes neuronales.

MNE-Python construye el modelo directo de forma explícita y por etapas, ensamblando el espacio de fuentes, la solución BEM y la transformación de coordenadas mediante funciones separadas. Esta modularidad incrementa la complejidad procedimental, dado que el usuario debe gestionar cada componente del modelo, pero otorga un control granular sobre la posición de las fuentes, que pueden situarse en coordenadas exactas sin mapeo a vértices predefinidos. La ventaja decisiva de la plataforma para los objetivos de este trabajo reside en su integración nativa con el ecosistema científico de Python: los datos generados se convierten directamente a arreglos NumPy y se interconectan sin pasos intermedios con scikit-learn, PyTorch o TensorFlow. Para un pipeline de generación de datos sintéticos destinado a alimentar clasificadores de aprendizaje profundo, esta interoperabilidad reduce la fricción de implementación y elimina las conversiones de formato que el flujo basado en MATLAB requeriría.

La verificación de que ambos ecosistemas producen datos estructuralmente equivalentes a partir de los mismos parámetros de entrada constituye un resultado metodológico de interés, ya que permite seleccionar la plataforma en función de criterios de integración y flexibilidad antes que por diferencias en la calidad intrínseca de la simulación. Para el estado del arte de la generación sintética de P300, este hallazgo sugiere que la decisión de ecosistema debe guiarse por el destino de los datos generados: SEREEGA resulta adecuado para estudios que operan íntegramente dentro del entorno MATLAB, mientras que MNE-Python ofrece ventajas estructurales cuando los datos sintéticos deben integrarse en cadenas de procesamiento basadas en aprendizaje automático moderno.

5.2. Limitaciones

El estudio presenta limitaciones que deben considerarse al interpretar sus resultados. La validación se realizó contra un único dataset y los datos de un solo sujeto, por lo que las conclusiones cuantitativas no son necesariamente generalizables a otras condiciones de registro o poblaciones. Asimismo, el modelo generativo emplea únicamente dos fuentes dipolares mediales, parietal y cingulada, y funciones gaussianas simétricas, lo que constituye una

simplificación de la red distribuida de generadores que subyace al P300 real.

La comparación contra datos reales reveló cinco brechas principales de realismo. La primera es la simetría temporal de la forma de onda, frente a la asimetría característica de subida rápida y caída lenta del P300 empírico. La segunda es la subestimación de la actividad frontal, que sugiere la existencia de generadores adicionales no contemplados en el modelo de dos dipolos. La tercera son las correlaciones negativas en canales temporales y laterales, no explicables por dos fuentes mediales. La cuarta es la estructura del ruido de fondo, que no reproduce la correlación espacial entre canales vecinos ni el detalle espectral del ruido real. La quinta es la variabilidad inter-ensayo reducida, inferior a la observada en registros biológicos genuinos.

5.3. Trabajo Futuro

Las brechas identificadas orientan directamente las líneas de mejora del trabajo, que se organizan en torno a tres ejes: el refinamiento del modelo generativo de señal, el escalamiento de los modelos de propagación y la experimentación avanzada con el componente P300 en escenarios aplicados.

5.3.1. Mejoras en la generación de la señal sintética

El refinamiento del modelo temporal constituye la línea de mejora más inmediata. La sustitución de las funciones gaussianas simétricas por funciones asimétricas, como la distribución gamma o la gaussiana con sesgo, permitiría reproducir la asimetría característica del P300 real, en la que la fase de subida es más rápida que la de caída. Una extensión natural consiste en modelar el P300 no como un componente único, sino como la superposición de sus subcomponentes P3a y P3b, cada uno con su propia latencia, distribución topográfica y generador neural diferenciado, lo que aproximaría la morfología sintética a la complejidad observada en los registros empíricos.

En el plano espacial, la incorporación de fuentes dipolares adicionales en regiones frontales, temporales y laterales mejoraría la fidelidad en los canales donde el modelo de dos dipolos mediales exhibe correlaciones negativas. La evidencia de que el P300 emerge de una red distribuida, y no de un par de generadores aislados, justifica la transición hacia configuraciones de fuentes múltiples cuya disposición y orientación se ajusten para reproducir la activación frontal subestimada por los modelos actuales. La estimación de las posiciones y orientaciones óptimas de estas fuentes a partir de problemas inversos resueltos sobre los propios datos empíricos representa una vía metodológica prometedora para anclar el modelo generativo a la anatomía funcional real.

El modelo de ruido admite mejoras sustanciales en al menos tres direcciones. La incorpora-

ción de correlación espacial entre canales vecinos reemplazaría el supuesto actual de ruido independiente por canal, que no refleja la estructura espacial del ruido biológico real. Una caracterización espectral más fiel, que reproduzca con precisión la pendiente $1/f$ en las frecuencias bajas y la interferencia de línea eléctrica, acercaría las propiedades frecuenciales del ruido sintético a las del registro empírico. La inclusión de artefactos representativos, como parpadeos oculares, contaminación muscular y derivas de la línea base, dotaría a los datos sintéticos de la complejidad necesaria para entrenar clasificadores robustos frente al ruido real. El aumento del rango del *jitter* paramétrico y la incorporación de fuentes de variabilidad biológica adicionales, como fluctuaciones de atención y fatiga cognitiva progresiva, permitirían reproducir la dispersión inter-ensayo observada en los datos empíricos y modelar la no estacionariedad que degrada la morfología del P300 a lo largo de una sesión.

5.3.2. Escalamiento de los modelos de propagación

La progresión de complejidad explorada en este trabajo, desde la esfera homogénea hasta los modelos BEM de tres capas, admite una extensión hacia modelos de mayor fidelidad. Los modelos basados en el Método de Elementos Finitos, que discretizan el volumen completo en elementos tetraédricos y permiten representar conductividades anisotrópicas dentro de cada tejido, constituyen el siguiente nivel de detalle anatómico. La evaluación de un modelo FEM, accesible mediante herramientas como SimBio o DUNEuro, frente a los modelos BEM aquí estudiados permitiría cuantificar si el incremento sustancial en costo computacional se traduce en una mejora medible de la fidelidad topográfica, una pregunta de relevancia directa para la viabilidad de la simulación masiva.

El escalamiento también comprende la dimensión poblacional del modelo de cabeza. La generación de datos sintéticos sobre múltiples modelos anatómicos individuales, en lugar de un único atlas, introduciría variabilidad inter-sujeto estructural en los datos generados, replicando la diversidad anatómica que un clasificador debe aprender a tolerar. Esta estrategia abordaría una de las causas raíz del sobreajuste en interfaces cerebro-computadora, dado que la variabilidad anatómica entre usuarios es una de las fuentes principales de fallo en la generalización fuera de distribución. La construcción de un repositorio de *leadfields* derivados de cohortes anatómicas amplias permitiría sintetizar datos que abarquen el espectro de geometrías craneales de una población objetivo.

5.3.3. Experimentación avanzada con el potencial P300

La validación realizada en este trabajo se limitó a un sujeto de un único dataset, por lo que su extensión a múltiples sujetos y a conjuntos de datos heterogéneos fortalecería la generalidad de las conclusiones y permitiría caracterizar la variabilidad de las métricas de fidelidad entre poblaciones y condiciones de registro. Una validación cruzada sobre datasets adquiridos con distintos equipos, montajes y paradigmas oddball establecería la robustez del procedimiento

de comparación propuesto.

La culminación natural de esta línea de investigación es la evaluación funcional de los datos sintéticos en la tarea para la que fueron concebidos. Más allá de las métricas de similitud morfológica y topográfica empleadas en este trabajo, el criterio decisivo de calidad para un simulador orientado al aumento de datos es su capacidad de mejorar el desempeño de un clasificador entrenado con datos reales escasos. Un protocolo experimental que entrene un modelo de aprendizaje profundo sobre una combinación de datos reales y sintéticos, y que mida la ganancia en exactitud de clasificación frente a un entrenamiento con datos reales únicamente, proporcionaría la evidencia funcional que las métricas de similitud no capturan por sí solas. Este enfoque permitiría establecer una correlación entre la fidelidad biofísica de cada modelo de propagación y su utilidad práctica como fuente de datos de aumento, cerrando el vínculo entre el realismo de la simulación y el objetivo último de superar la escasez de datos empíricos en interfaces cerebro-computadora basadas en P300.

La integración del *ground truth* espacial de los modelos paramétricos evaluados con técnicas generativas complementarias, como las redes generativas antagónicas o los modelos de difusión entrenados sobre datos empíricos, constituye un paradigma híbrido de simulación de alto potencial. Tal enfoque combinaría la interpretabilidad y el control anatómico de los modelos basados en física con la capacidad de las técnicas de aprendizaje profundo para capturar la variabilidad estadística de los datos reales, abordando de forma conjunta las brechas de realismo morfológico, espectral y de variabilidad inter-ensayo identificadas en este trabajo.

REFERENCIAS BIBLIOGRÁFICAS

- [Blankertz *et al.*, 2006] Blankertz, B., Muller, K.-R., Krusienski, D. J., Schalk, G., Wolpaw, J. R., Schlogl, A., Pfurtscheller, G., Millan, J. d. R., Schroder, M., y Birbaumer, N. (2006). The BCI competition III: validating alternative approaches to actual BCI problems. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 14(2):153–159.
- [Buzsáki, 2006] Buzsáki, G. (2006). *Rhythms of the Brain*. Oxford University Press, New York.
- [Delorme y Makeig, 2004] Delorme, A. y Makeig, S. (2004). EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of Neuroscience Methods*, 134(1):9–21.
- [Farwell y Donchin, 1988] Farwell, L. A. y Donchin, E. (1988). Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and Clinical Neurophysiology*, 70(6):510–523.
- [Fischl, 2012] Fischl, B. (2012). FreeSurfer. *NeuroImage*, 62(2):774–781.
- [Geddes y Baker, 1967] Geddes, L. A. y Baker, L. E. (1967). The specific resistance of biological material—a compendium of data for the biomedical engineer and physiologist. *Medical and Biological Engineering*, 5(3):271–293.
- [Gramfort *et al.*, 2013] Gramfort, A., Luessi, M., Larson, E., Engemann, D. A., Strohmeier, D., Brodbeck, C., Goj, R., Jas, M., Brooks, T., Parkkonen, L., y Hämäläinen, M. (2013). MEG and EEG data analysis with MNE-Python. *Frontiers in Neuroscience*, 7:267.
- [Gramfort *et al.*, 2014] Gramfort, A., Luessi, M., Larson, E., Engemann, D. A., Strohmeier, D., Brodbeck, C., Parkkonen, L., y Hämäläinen, M. S. (2014). MNE software for processing MEG and EEG data. *NeuroImage*, 86:446–460.
- [Hallez *et al.*, 2007] Hallez, H., Vanrumste, B., Grech, R., Muscat, J., De Clercq, W., Vergult, A., D'Asseler, Y., Camilleri, K. P., Fabri, S. G., Van Huffel, S., y Lemahieu, I. (2007). Review on solving the forward problem in EEG source analysis. *Journal of NeuroEngineering and Rehabilitation*, 4(1):46.
- [Huang *et al.*, 2016] Huang, Y., Parra, L. C., y Haufe, S. (2016). The New York Head—a precise standardized volume conductor model for EEG source localization and tES targeting. *NeuroImage*, 140:150–162.
- [Jasper, 1958] Jasper, H. H. (1958). The ten-twenty electrode system of the International Federation. *Electroencephalography and Clinical Neurophysiology*, 10:371–375.
- [Kappenman y Luck, 2010] Kappenman, E. S. y Luck, S. J. (2010). The effects of electrode impedance on data quality and statistical significance in ERP recordings. *Psychophysiology*, 47(5):888–904.

- [Krol *et al.*, 2018] Krol, L. R., Pawlitzki, J., Lotte, F., Gramann, K., y Zander, T. O. (2018). SE-REEGA: Simulating event-related EEG activity. *Journal of Neuroscience Methods*, 309:13–24.
- [Lotte *et al.*, 2018] Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., y Yger, F. (2018). A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. *Journal of Neural Engineering*, 15(3):031005.
- [Luck, 2014] Luck, S. J. (2014). *An Introduction to the Event-Related Potential Technique*. MIT Press, Cambridge, MA, 2 edición.
- [Niedermeyer y da Silva, 2004] Niedermeyer, E. y da Silva, F. L. (2004). *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. Lippincott Williams & Wilkins, Philadelphia, 5 edición.
- [Nunez y Srinivasan, 2006] Nunez, P. L. y Srinivasan, R. (2006). *Electric Fields of the Brain: The Neurophysics of EEG*. Oxford University Press, New York, 2 edición.
- [Polich, 2007] Polich, J. (2007). Updating P300: An integrative theory of P3a and P3b. *Clinical Neurophysiology*, 118(10):2128–2148.
- [Sutton *et al.*, 1965] Sutton, S., Braren, M., Zubin, J., y John, E. R. (1965). Evoked-potential correlates of stimulus uncertainty. *Science*, 150(3700):1187–1188.
- [Teplan, 2002] Teplan, M. (2002). Fundamentals of EEG measurement. *Measurement Science Review*, 2(2):1–11.
- [Wolpaw *et al.*, 2002] Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., y Vaughan, T. M. (2002). Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, 113(6):767–791.