



**UNIVERSIDAD DE VALLADOLID**

ESCUELA TÉCNICA SUPERIOR DE INGENIEROS DE TELECOMUNICACIÓN

**TRABAJO FIN DE GRADO**

GRADO EN INGENIERÍA DE TECNOLOGÍAS DE TELECOMUNICACIÓN

**DETECTOR AUTOMÁTICO DE ARTEFACTOS EN  
SEÑALES NEURONALES BASADO EN TÉCNICAS  
DE INTELIGENCIA ARTIFICIAL**

AUTORA:

**DÑA. AMALIA GIL CORREA**

TUTORES:

**DR. D. JESÚS POZA CRESPO**

**D. SERGIO PÉREZ VELASCO**

**D. VÍCTOR RODRÍGUEZ GONZÁLEZ**

---

**TÍTULO:**                    **Detector automático de artefactos en  
señales neuronales basado en técnicas  
de inteligencia artificial**

**AUTOR:**                    **Dña. Amalia Gil Correa**

**TUTOR/ES:**                **Dr. D. Jesús Poza Crespo  
D. Sergio Pérez Velasco  
D. Víctor Rodríguez González**

**DEPARTAMENTO:** **Teoría de la Señal y Comunicaciones  
e Ingeniería Telemática**

---

**TRIBUNAL**

---

**PRESIDENTE:**            **Roberto Hornero Sánchez**

**SECRETARIO:**            **Carlos Gómez Peña**

**VOCAL:**                    **Jesús Poza Crespo**

**P. SUPLENTE:**            **María García Gadañón**

**V. SUPLENTE:**            **Mario Martínez Zarzuela**

---

**FECHA:**

**CALIFICACIÓN:**

---

A mis padres

---

# Agradecimientos

En primer lugar, quiero agradecer a Jesús Poza Crespo, Sergio Pérez Velasco y Víctor Rodríguez González su implicación como tutores en este proyecto, por las recomendaciones aportadas y, sobre todo, por abrirme las puertas ante el maravilloso mundo de la investigación y la Ingeniería Biomédica. A mis compañeros de laboratorio, que me habéis acompañado desde el comienzo y habéis aportado vuestro granito de arena en este proyecto. Gracias en especial a Sergio, por haberme llevado de la mano desde el primer minuto.

A mis padres, por apoyarme siempre y ayudarme a ver el lado positivo de las cosas.

A Isa, Jose y Pablo, porque para mí seguís siendo admirables. Gracias también a Carlos, Aitana y Pilar.

A PF, por aguantarme todos estos años y por darme un motivo para sonreír todos los días.

A mis amigas que, aunque nos veamos cuatro veces al año, hacéis que las cosas sigan como siempre cuando estamos juntas.

Por último, quiero agradecer también este trabajo a Estela, Sara, Gabriel, Elsa y Manuel. Sin vosotros todo este proceso hubiera sido inalcanzable.

---

# Resumen

Los campos electromagnéticos generados en el cerebro reflejan el estado cognitivo de las personas, pudiendo manifestar enfermedades o condiciones que afectan al sistema nervioso central. La electroencefalografía (EEG) y la magnetoencefalografía (MEG) son técnicas no invasivas que permiten detectar los campos electromagnéticos generados por la actividad cerebral. Ambas se pueden combinar para obtener información completa sobre el cerebro. Sin embargo, tanto las señales EEG como las MEG pueden estar contaminadas por interferencias de origen no neuronal, afectando gravemente su calidad y, como consecuencia, sesgando a posibles interpretaciones que se puedan derivar de ellas. Por lo tanto, resulta necesario mitigar el efecto de este ruido o artefactos, minimizando su presencia antes de analizar los datos. Uno de los métodos más empleados hoy en día para abordar este problema es el Análisis de Componentes Independientes (ICA). ICA es un método estadístico que permite separar las distintas componentes que generan los datos EEG y MEG. Sin embargo, esta técnica no ofrece una clasificación en función del origen de las componentes independientes en las que descomponen las señales, sino que depende de la interpretación subjetiva de un técnico mediante análisis visual.

Este Trabajo Fin de Grado se ha enfocado en el desarrollo de un sistema basado en *Deep Learning* (DL) que, haciendo uso de la Red Neuronal Convolutiva EEG-Inception, permite diferenciar y clasificar las componentes ICA de origen neuronal y las componentes artefactuadas. Para ello, se han diseñado y evaluado dos sistemas de clasificación diferentes: clasificación binaria y clasificación multiclase. La primera se centra en identificar la presencia de artefactos en la señal MEG, independientemente del origen de la componente ruidosa, mientras que la segunda busca detectar la presencia de artefactos de diferentes orígenes en la señal registrada, y realizar una clasificación de estos en una categoría específica.

Para llevar a cabo esta tarea, se empleó una base de datos formada por componentes ICA, obtenidas a partir de 5 minutos de actividad MEG en estado de reposo

---

y con los ojos cerrados de 473 sujetos. Los resultados obtenidos en la clasificación binaria ofrecen una precisión del 96.92 %, con una sensibilidad del 67.14 % y una especificidad del 98.56 %. En la clasificación multiclase se consiguió una precisión global del 86.90 % y una especificidad global del 88.13 %, mientras que las sensibilidades para cada una de las clases fueron diversas: 74.41 % en la componente cardíaca, 42.85 % en la componente asociada a la red eléctrica, 81.39 % en la componente ocular, y 25 % frente a otro tipo de componentes. Además, la propia red realizó un re-etiquetado de las componentes ICA, lo que reveló que algunas de ellas estaban mal identificadas en la base de datos o que la clasificación realizada originalmente por el técnico era dudosa. Por lo tanto, la herramienta propuesta no solo mejora la clasificación automática de las componentes ICA, sino que también puede mejorar y ayudar en el etiquetado manual efectuado por los técnicos.

## Palabras clave

Electroencefalografía, magnetoencefalografía, artefactos, *Deep Learning*, Redes Neuronales Convolucionales, EEG-Inception, clasificación.

---

# Abstract

The electromagnetic fields generated in the brain reflect a person's cognitive state and can manifest diseases or conditions affecting the central nervous system. Electroencephalography (EEG) and magnetoencephalography (MEG) are non-invasive techniques for detecting electromagnetic fields generated by brain activity. Both can be combined to obtain comprehensive information about the brain. However, EEG and MEG signals can be contaminated by artefacts from non-neuronal origin, severely affecting their quality and, as a consequence, biasing the possible interpretations that can be derived from them. It is therefore necessary to mitigate the effect of this noise or artefacts by minimising their presence before analysing the data. Nowadays, one of the most widely used methods to address this problem is the Independent Component Analysis (ICA). ICA is a statistical method that allows the separation of the different components that generate EEG and MEG data. However, this technique does not provide an origin-based classification of the independent components into which it decomposes the signals, but depends on the subjective interpretation of a technician by visual analysis.

This Final Degree Project has focused on the development of a system based on Deep Learning (DL) that, making use of the EEG-Inception Convolutional Neural Network, allows differentiating and classifying ICA components of neural origin and artefactual components. For this purpose, two different classification systems have been designed and evaluated: binary classification and multiclass classification. The former focuses on identifying the presence of artefacts in the MEG signal, disregarding the origin of the noisy component, while the latter is aimed at detecting the presence of artefacts of different origins in the recorded signal, and at classifying them into a specific category.

To perform these tasks, a database of ICA components, obtained from 5 minutes of resting and eyes-closed MEG activity of 473 subjects, was used. The results obtained in the binary classification provided an accuracy of 96.92%, with a sen-

---

sitivity of 67.14 % and a specificity of 98.56 %. In the multiclass classification, an overall accuracy of 86.90 % and an overall specificity of 88.13 % was achieved, while the sensitivities for each of the classes were diverse: 74.41 % in the cardiac component, 42.85 % in the component associated with the electrical network, 81.39 % in the ocular component, and 25.00 % against other types of components. In addition, the network itself re-labelled the ICA components, which revealed that some of them were misidentified in the database or that the classification originally made by the technician was doubtful. Therefore, the proposed tool not only improves the automatic classification of ICA components, but can also improve and help in the manual labelling performed by technicians.

## Keywords

Electroencephalography, magnetoencephalography, artefacts, Deep Learning, Convolutional Neural Networks, EEG-Inception, classification.

---

# Índice General

<b>1. Introducción</b>	<b>15</b>
1.1. Ingeniería Biomédica y procesamiento de señales neuronales . . . . .	16
1.2. Artefactos en señales neuronales . . . . .	16
1.3. Inteligencia Artificial: <i>Deep Learning</i> . . . . .	17
1.4. Motivación . . . . .	19
1.5. Hipótesis . . . . .	19
1.6. Objetivos . . . . .	20
1.7. Estructura del documento . . . . .	20
<b>2. Señales electromagnéticas cerebrales: electroencefalogramas y magnetoencefalogramas</b>	<b>23</b>
2.1. Introducción . . . . .	24
2.2. Historia y evolución de la tecnología . . . . .	24
2.3. Adquisición y procesamiento de señales EEG y MEG . . . . .	25
2.3.1. Señales EEG . . . . .	26
2.3.2. Señales MEG . . . . .	27
2.4. Ventajas y desventajas de EEG y MEG . . . . .	28
2.5. Limitaciones y desafíos en la interpretación de MEG . . . . .	29
<b>3. Artefactos en señales neuronales</b>	<b>31</b>
3.1. Introducción . . . . .	32
3.2. Impacto de la presencia de artefactos . . . . .	36
3.3. Técnicas de detección de artefactos en señales de actividad cerebral .	38
3.4. Aplicaciones de la Inteligencia Artificial en la detección de artefactos	39
<b>4. Redes Neuronales Convolucionales</b>	<b>42</b>
4.1. Introducción . . . . .	43
4.2. Métodos de entrenamiento y optimización . . . . .	44

---

<b>5. Materiales y Métodos</b>	<b>47</b>
5.1. Introducción . . . . .	48
5.2. Base de datos . . . . .	48
5.3. Diseño y desarrollo de un detector automático de artefactos basado en <i>Deep Learning</i> . . . . .	51
5.3.1. Configuración de la red EEG-Inception . . . . .	51
5.3.2. Métricas de evaluación . . . . .	54
5.3.3. Modelos de clasificación . . . . .	58
5.3.4. Re-evaluación de las componentes . . . . .	59
<b>6. Resultados</b>	<b>61</b>
6.1. Introducción . . . . .	62
6.2. Hiperparámetros escogidos . . . . .	62
6.3. Resultados de la clasificación . . . . .	64
6.3.1. Clasificación binaria . . . . .	64
6.3.2. Clasificación multiclase . . . . .	65
6.4. Re-evaluación y visualización de componentes . . . . .	67
<b>7. Discusión y limitaciones</b>	<b>71</b>
7.1. Introducción . . . . .	72
7.2. Discusión . . . . .	72
7.3. Limitaciones . . . . .	75
<b>8. Conclusión y líneas futuras</b>	<b>79</b>
8.1. Introducción . . . . .	80
8.2. Objetivos propuestos . . . . .	80
8.3. Conclusiones y aportaciones . . . . .	81
8.4. Líneas futuras . . . . .	81
<b>Bibliografía</b>	<b>83</b>

---

# Índice de Figuras

2.1. Sistema Internacional 10-20 para EEG (Sepúlveda <i>et al.</i> , 2015). . . . .	26
3.1. Izquierda: 10 segundos de señal EEG contaminada con artefactos musculares. Derecha: 21 canales contaminados con actividad ocular y muscular (Islam <i>et al.</i> , 2016). . . . .	32
3.2. Componente ICA asociada a actividad cardíaca recogida en un registro EEG. Esquina superior izquierda: topografía de la cabeza donde se representa la posición de los electrodos, en rojo la parte que más contribuye en la generación del artefacto cardíaco y en azul la que menos. A su derecha: señal en el dominio del tiempo. Esquina inferior izquierda: potencia de la componente durante todo el registro. A su derecha: localización de fuentes estimada que mejor se aproximan a la topografía calculada. Esquina inferior derecha: señal en el dominio de la frecuencia (ICL, 2023). . . . .	33
3.3. Componente ICA asociada a actividad muscular. Esquina superior izquierda: topografía de la cabeza donde se representa la posición de los electrodos, en rojo la parte que más contribuye en la generación del artefacto muscular y en azul la que menos. A su derecha: señal en el dominio del tiempo. Esquina inferior izquierda: potencia de la componente durante todo el registro. A su derecha: localización de fuentes estimada que mejor se aproximan a la topografía calculada. Esquina inferior derecha: señal en el dominio de la frecuencia (ICL, 2023). . . . .	34

---

3.4.	Componente ICA asociada a actividad ocular. Esquina superior izquierda: topografía de la cabeza donde se representa la posición de los electrodos, en rojo la parte que más contribuye en la generación del artefacto ocular y en azul la que menos. A su derecha: señal en el dominio del tiempo. Esquina inferior izquierda: potencia de la componente durante todo el registro. A su derecha: localización de fuentes estimada que mejor se aproximan a la topografía calculada. Esquina inferior derecha: señal en el dominio de la frecuencia (ICL, 2023). . . . .	35
3.5.	Componente ICA asociada a la red eléctrica. Esquina superior izquierda: topografía de la cabeza donde se representa la posición de los electrodos, en rojo la parte que más contribuye en la generación del artefacto asociado a la red eléctrica y en azul la que menos. A su derecha: señal en el dominio del tiempo. Esquina inferior izquierda: potencia de la componente durante todo el registro. A su derecha: localización de fuentes estimada que mejor se aproximan a la topografía calculada. Esquina inferior derecha: señal en el dominio de la frecuencia. . . . .	36
3.6.	Señales EEG en las cinco bandas de frecuencia convencionales utilizadas en estudios neurofisiológicos (Sanei y Chambers, 2013). . . . .	37
3.7.	Estimación de la PSD. En rojo la señal EEG con artefactos, en verde la señal EEG sin artefactos (Zangeneh Soroush <i>et al.</i> , 2022). . . . .	38
4.1.	Arquitectura simple de una CNN formada por 5 capas (O’Shea y Nash, 2015). . . . .	43
4.2.	<i>Average-Pooling</i> y <i>Max-Pooling</i> en una matriz 4x4 aplicando una ventana de 2x2. . . . .	46
5.1.	Componente etiquetada como cerebral. Imagen Superior: Señal de 5 minutos de duración muestreada a 1000 Hz, de la cual se ha obtenido la señal de 60000 muestras de duración. Imagen Inferior: densidad espectral de potencia de la señal (PSD, <i>Power Spectral Density</i> ). . . . .	49
5.2.	Componente etiquetada como cardíaca. . . . .	50
5.3.	Componente etiquetada como red eléctrica. . . . .	50
5.4.	Componente etiquetada como ocular. . . . .	51
5.5.	Arquitectura general de la red EEG-Inception (Santamaria-Vazquez <i>et al.</i> , 2020). . . . .	52

---

5.6.	Arquitectura de la red EEG-Inception adaptada en este TFG. . . . .	53
5.7.	División del conjunto de sujetos en los conjuntos de entrenamiento y prueba haciendo uso de <i>k-fold</i> . . . . .	55
5.8.	Artefactos totales en cada componente. . . . .	56
5.9.	Matrices de confusión empleadas. . . . .	58
6.1.	Distribución de artefactos totales (en azul), falsos positivos (en verde) y falsos negativos (en rojo) para las 40 primeras componentes. . . . .	65
6.2.	Matriz de confusión obtenida tras la clasificación binaria para las 40 primeras componentes. . . . .	66
6.3.	Matriz de confusión obtenida tras la clasificación multiclase para las 40 primeras componentes. . . . .	67
6.4.	Cuatro componentes etiquetadas como no artefacto eliminadas de la base de datos por considerarse dudosas ( <i>score</i> menor del 90 % en la clase no artefacto.) (a) Componente etiquetada como no artefacto (0), y la red ha predicho artefacto (1). <i>Score</i> del 30 %. (b) Componente etiquetada como no artefacto (0), y la red ha predicho no artefacto (0). <i>Score</i> del 89 %. (c) Componente etiquetada como no artefacto (0), y la red ha predicho artefacto (1). <i>Score</i> del 39 %. (d) Componente etiquetada como no artefacto (0), y la red ha predicho artefacto (1). <i>Score</i> del 31 %. . . . .	70

---

# Índice de Tablas

6.1. Parámetros y resultados tras analizar las 160 componentes en una clasificación binaria. . . . .	63
6.2. Parámetros y resultados tras analizar las 40 primeras componentes en una clasificación binaria. . . . .	63
6.3. Parámetros y resultados tras analizar la clasificación multiclase. S1: sensibilidad frente a la componente cardíaca; S2: sensibilidad frente a la red eléctrica; S3: sensibilidad frente a la ocular; S4: sensibilidad frente a otro tipo de componentes. . . . .	64
6.4. Parámetros y resultados finales tras analizar las 40 primeras componentes en una clasificación binaria. . . . .	64
6.5. Parámetros y resultados finales tras analizar la clasificación multiclase. S1: sensibilidad frente a la componente cardíaca; S2: sensibilidad frente a la red eléctrica; S3: sensibilidad frente a la ocular; S4: sensibilidad frente a otro tipo de componentes. . . . .	66
6.6. Matrices de confusión, sensibilidad, especificidad, precisión y coeficientes <i>kappa</i> obtenidos tras cada simulación con una escala de tiempos de (500, 250, 125). . . . .	68
6.7. Matrices de confusión, sensibilidad, especificidad, precisión y coeficientes <i>kappa</i> obtenidos tras cada simulación con una escala de tiempos de (125, 125). . . . .	69
6.8. Matrices de confusión, sensibilidad, especificidad, precisión y coeficientes <i>kappa</i> obtenidos tras varias simulaciones en las que se van eliminando componentes “dudosas” hasta que la red no mejore más los resultados. . . . .	69
7.1. Estudios realizados para la detección de artefactos en señales neuronales.	76

---

# Capítulo 1

## Introducción

### Índice

---

1.1. Ingeniería Biomédica y procesamiento de señales neuronales	16
1.2. Artefactos en señales neuronales . . . . .	16
1.3. Inteligencia Artificial: <i>Deep Learning</i> . . . . .	17
1.4. Motivación . . . . .	19
1.5. Hipótesis . . . . .	19
1.6. Objetivos . . . . .	20
1.7. Estructura del documento . . . . .	20

---

### 1.1. Ingeniería Biomédica y procesamiento de señales neuronales

La Ingeniería Biomédica es una rama de conocimiento multidisciplinar que, mediante la aplicación de principios de las matemáticas, física e ingeniería al campo de la medicina, permite el diseño y fabricación de instrumentos para su interacción con el ser humano, buscando una mejora en su calidad de vida (Pardo, 2023). Los sistemas fisiológicos, tales como el cardiovascular, nervioso, respiratorio, gastrointestinal, auditivo o visual, son objeto de estudio dentro de esta disciplina. Es importante destacar que una de las áreas con mayor relevancia en la actualidad es la correspondiente al procesamiento de señales biomédicas de origen neuronal, que además va a ser objeto de estudio en el presente Trabajo Fin de Grado (TFG).

Durante el procesamiento de señales neuronales se emplean técnicas que permiten analizar señales electromagnéticas, con el fin de extraer información del sistema biológico en cuestión, en este caso el cerebro, para su posterior diagnóstico o monitorización (Cohen, 2006). La señal adquirida es una señal originada a través de la compleja configuración microcircuitual neuronal, donde diversas clases de células y capas dentro del córtex interactúan para producir señales electromagnéticas con distintas características espaciales, temporales y frecuenciales que están asociadas a procesos cognitivos (Cohen, 2017). Aquí es donde toma un papel importante la sinapsis, que se trata de un fenómeno fisiológico que tiene lugar cuando las células nerviosas (*i.e.*, las neuronas) son estimuladas a través de la liberación de neurotransmisores por parte de una neurona adyacente (Poza Crespo, 2008). Entre las principales contribuciones a la generación de las señales neuronales se encuentra el intercambio electroquímico que ocurre durante la sinapsis (Lopes da Silva, 2013).

Este TFG se va a centrar en la señal biomédica procedente de magnetoencefalogramas (MEG), es decir, el registro de los campos magnéticos emitidos por nuestro cerebro. Más adelante, en el Capítulo 2, se hará especial mención a este tipo de señales que, junto con el electroencefalograma (EEG), son los métodos no invasivos más potentes para examinar la actividad electromagnética del cerebro (Cohen, 2017).

### 1.2. Artefactos en señales neuronales

Garantizar la obtención de datos limpios y precisos es uno de los principales retos a los que se enfrentan los ingenieros biomédicos, tras haber adquirido una señal

## 1 Introducción

---

neuronal procedente de un registro EEG o MEG. La presencia de ruido, también denominado artefacto, proveniente de fuentes ajenas a la actividad cerebral, puede interferir con la señal. Los artefactos provocan una disminución en la relación señal a ruido (SNR, *Signal to Noise Ratio*) y, como consecuencia, pueden empeorar en gran medida la calidad de la señal neuronal y, por tanto, la fiabilidad de las conclusiones extraídas de su análisis.

Existen dos categorías principales de artefactos, que dependen de su origen (Team, 2023): fisiológicos y no fisiológicos. Los primeros proceden de la propia actividad corporal del paciente, como por ejemplo actividad cardíaca (*i.e.*, electrocardiograma o ECG), ocular (electrooculograma o EOG), muscular (electromiograma o EMG) o respiratoria. Se caracterizan por ser en su mayoría periódicos y continuos, como los parpadeos o los latidos del corazón, o por estar situados en altas frecuencias, como los movimientos musculares. Los segundos, también denominados artefactos técnicos, son externos al cuerpo humano, y pueden surgir de interferencias eléctricas y electromagnéticas debidas a aparatos eléctricos cercanos, movimientos de los cables que van conectados a los aparatos de medición, o una mala colocación de los electrodos utilizados para registrar la señal (Team, 2023).

La eliminación o atenuación de estos artefactos, que enmascaran la señal neuronal, es de vital importancia para el estudio y manejo por parte de los médicos para el diagnóstico de posibles enfermedades, como por ejemplo, la enfermedad de Alzheimer (EA) o crisis epilépticas (Mahmud *et al.*, 2012). Actualmente, y como se comentará más detalladamente en el Capítulo 3 de este TFG, esta detección y eliminación de artefactos se realiza de manera visual por unos técnicos especializados en la materia. Se trata, por tanto, de una tarea ardua y costosa, sobre todo si la cantidad de datos obtenidos tras el registro es muy elevada. Además, conlleva el riesgo de introducir errores en la clasificación, dado que implica un alto grado de subjetividad.

Parece pertinente, por tanto, desarrollar alguna herramienta de detección automática y objetiva de artefactos en señales neuronales que facilite la tarea a los técnicos y ofrezca resultados fiables en un corto período de tiempo.

### 1.3. Inteligencia Artificial: *Deep Learning*

Ante la heterogeneidad presente en las distintas componentes que conforman un registro EEG o MEG, resulta imprescindible implementar alguna técnica adicional

## 1 Introducción

---

al filtrado de la señal para poder detectar y eliminar las componentes artefactuadas. Para ello, el Análisis de Componentes Independientes (ICA, *Independent Component Analysis*) es muy empleado, pues permite separar las distintas componentes que componen la señal adquirida. Sin embargo, su clasificación es efectuada de forma manual por expertos, lo que puede generar errores y demandar un tiempo considerable (Croce *et al.*, 2019).

La Inteligencia Artificial (AI, *Artificial Intelligence*) constituye una herramienta que permite imitar la inteligencia humana y realizar tareas complejas, desde proponer soluciones a problemas cotidianos a profundizar en el trabajo cognitivo, o diseñar e implementar sistemas inteligentes de apoyo o ayuda a la decisión (Callier y Sandel, 2021). El Aprendizaje Automático o *Machine Learning* (ML) es considerada la familia de técnicas de AI más relevante debido a su habilidad para dotar a los sistemas de la capacidad de aprendizaje a través de un conjunto de datos de entrenamiento; esto les permite automatizar el procesado de un modelo analítico y resolver tareas específicas. Por otro lado, el Aprendizaje Profundo, también conocido como *Deep Learning* (DL), es un término perteneciente al campo de ML que se basa en la utilización de redes neuronales artificiales, que son modelos matemáticos inspirados en el funcionamiento del cerebro humano. Estos modelos están formados por nodos, denominados neuronas artificiales, que se conectan entre sí para procesar la información mediante operaciones matemáticas y algoritmos basados en AI (Janiesch *et al.*, 2021).

Con el objetivo de minimizar la complejidad y subjetividad que están inherentemente presentes en la detección de artefactos en señales neuronales, en este TFG se ha optado por emplear una técnica de AI que permita facilitar dicho proceso, haciéndolo lo más objetivo posible para ofrecer resultados fiables en un corto período de tiempo. En concreto, se ha planteado una herramienta basada en *deep learning*, dado que supera en gran medida al modelo de *machine learning* para este estudio. Esto se debe a su mayor capacidad de aprendizaje con un elevado número de datos no estructurados, permitiendo analizar y clasificar la señal sin necesidad de que se extraigan características previas, y su analogía con las redes neuronales propias del ser humano. Además, funciona mejor en otros campos como la visión por ordenador y el procesamiento de lenguaje natural (O'Shea y Nash, 2015).

### 1.4. Motivación

La detección y eliminación de artefactos en señales neuronales es un problema crucial en el campo de la biomedicina, ya que estos artefactos pueden comprometer la calidad de las mediciones realizadas a partir de estas señales. En este contexto, el uso de técnicas de DL, más concretamente las redes neuronales convolucionales (CNN, *Convolutional Neural Networks*), se presenta como una alternativa prometedora para la detección y eliminación automática de artefactos en señales neuronales. La eficacia de estas técnicas en tareas similares de procesamiento de señales y su capacidad para procesar grandes volúmenes de datos ha motivado que en el presente TFG se explore su potencial, con un enfoque particular en la detección de artefactos en componentes independientes de señales MEG. Se espera que los resultados obtenidos puedan tener un impacto significativo en el campo del análisis de estas señales, mejorando su calidad y, por tanto, el diagnóstico y seguimiento de enfermedades cerebrales, mejorando la calidad de vida de los pacientes.

### 1.5. Hipótesis

La presencia de artefactos en señales neuronales constituye un obstáculo significativo en la detección temprana y el diagnóstico preciso de enfermedades cerebrales como la demencia debida a enfermedad de Alzheimer o la migraña. Esta complejidad se ve agravada por el tiempo y la dificultad que implica la eliminación de estos artefactos y por la subjetividad de los resultados obtenidos en la subsecuente interpretación de las señales, retrasando el inicio del tratamiento y afectando negativamente la evolución clínica de los pacientes. En este TFG se parte de la hipótesis de que las redes neuronales convolucionales pueden emplearse para la detección y clasificación de artefactos, dado su potencial para extraer información de señales neuronales. Un entrenamiento adecuado de estas redes puede permitir la identificación de componentes independientes asociadas a ruido y actividad cerebral, lo que facilitaría el trabajo del técnico encargado del etiquetado y reduciría el tiempo necesario para esta tarea. Dependiendo de la precisión alcanzada, se podría llegar a automatizar la tarea por completo.

### 1.6. Objetivos

Este TFG tiene como objetivo principal el desarrollo de una herramienta que permita la detección y posterior clasificación de artefactos presentes en señales neuronales. Para ello, se han aplicado técnicas de Inteligencia Artificial que posibilitan automatizar el proceso y reducir costes a la hora de llevar a cabo una clasificación de las componentes independientes provenientes de registros MEG en estado de reposo. Para poder cumplimentar el objetivo principal, se han propuesto los siguientes objetivos secundarios:

1. Familiarizarse con las propiedades de las señales electromagnéticas cerebrales, EEG y MEG, y entender las técnicas de procesamiento más habituales para su estudio.
2. Conocer los distintos tipos de artefactos que pueden estar presentes en una señal neuronal, así como las posibles técnicas que se pueden aplicar para mitigar sus efectos.
3. Entender el concepto de red neuronal y relacionarlo con DL, e investigar sobre los métodos de entrenamiento y optimización más comúnmente empleados hasta la fecha.
4. Diseñar e implementar una herramienta basada en AI y aplicarla a señales MEG en estado de reposo, proporcionadas por el Hospital Hokuto (Japón).
5. Evaluar los dos modelos diferentes de detección y clasificación de artefactos (*i.e.*, binaria y multiclase) y estudiar la precisión y estabilidad en base a los hiperparámetros de la red escogidos.
6. Analizar los resultados obtenidos con la herramienta diseñada, evaluando su rendimiento y comparándolo con estudios previos.
7. Extraer conclusiones e identificar las posibles limitaciones y líneas futuras.

### 1.7. Estructura del documento

Este documento consta de 8 capítulos, que se estructuran de la manera que se indica a continuación:

- **Capítulo 1. Introducción.** Este primer capítulo ofrece una breve introducción a la Ingeniería Biomédica y al área de procesado de señales biomédicas de origen neuronal. Se introduce el concepto de artefactos en señales neuronales y, además, se presentan algunos de los conceptos clave de la AI, haciendo especial mención a la parte de Aprendizaje Profundo. También se muestran las razones que han motivado a hacer este TFG, las hipótesis de partida y los objetivos principales que se deben conseguir tras la ejecución de este trabajo.
- **Capítulo 2. Señales electromagnéticas cerebrales: electroencefalogramas y magnetoencefalogramas.** En este capítulo se comienza hablando de las señales EEG y MEG, su historia, evolución y aplicaciones de ambas técnicas. Se explica cómo se obtienen las señales neuronales a partir de ellas, y la razón que ha llevado a este TFG a centrarse únicamente en MEG. Por último, se exponen las limitaciones y desafíos que conlleva esta última técnica.
- **Capítulo 3. Artefactos en señales neuronales.** En este tercer capítulo se definen los tipos de artefactos más comunes que se pueden encontrar en una señal MEG, y el impacto que tiene dicha presencia a la hora de analizar las señales cerebrales. También se mencionan las técnicas empleadas históricamente en la detección de artefactos y, finalmente, se profundiza en aquellas que hayan aplicado métodos de AI.
- **Capítulo 4. Redes Neuronales Convolucionales.** En el capítulo 4 de esta memoria se analiza el concepto de redes neuronales y su aplicación en el Aprendizaje Profundo. A mayores, se comentan cuáles son los métodos de entrenamiento y optimización más empleados hasta la fecha.
- **Capítulo 5. Materiales y métodos.** En este capítulo se explican las características de la base de datos utilizada, así como el tipo de sujetos con los que se está trabajando. Seguidamente, se describe detalladamente la herramienta diseñada junto con la metodología aplicada para evaluar la detección y clasificación de artefactos en señales neuronales. Se profundiza en los tipos de clasificación que se han llevado a cabo y, por último, se explican los métodos de evaluación del rendimiento de la herramienta.
- **Capítulo 6. Resultados.** En el sexto capítulo se presentan los resultados obtenidos con los dos tipos de clasificaciones empleados y se comparan con otros resultados conseguidos tras la modificación de diferentes parámetros de

la red. Además, se lleva a cabo un re-etiquetado efectuado por la propia red mediante la exclusión de ciertas componentes consideradas dudosas en una primera instancia.

- **Capítulo 7. Discusión y limitaciones.** En este capítulo se evalúa la clasificación obtenida con los resultados conseguidos por los técnicos que realizan la clasificación manual. Asimismo, se describen y comparan los resultados obtenidos con otras técnicas desarrolladas por otros investigadores. Además, se discuten las limitaciones y otros posibles puntos de vista que podrían complementar el desarrollo de esta herramienta.
- **Capítulo 8. Conclusiones y líneas futuras.** En este último capítulo se indican las conclusiones extraídas y las aportaciones realizadas por la metodología desarrollada durante el TFG, así como las aplicaciones y posible continuación para mejorar la herramienta diseñada.

---

## Capítulo 2

# Señales electromagnéticas cerebrales: electroencefalogramas y magnetoencefalogramas

### Índice

---

<b>2.1. Introducción . . . . .</b>	<b>24</b>
<b>2.2. Historia y evolución de la tecnología . . . . .</b>	<b>24</b>
<b>2.3. Adquisición y procesamiento de señales EEG y MEG . .</b>	<b>25</b>
2.3.1. Señales EEG . . . . .	26
2.3.2. Señales MEG . . . . .	27
<b>2.4. Ventajas y desventajas de EEG y MEG . . . . .</b>	<b>28</b>
<b>2.5. Limitaciones y desafíos en la interpretación de MEG . .</b>	<b>29</b>

---

## 2.1. Introducción

El cerebro es uno de los órganos más complejos del ser humano: la cantidad de operaciones y procesos que debe realizar delimita el correcto funcionamiento de cada individuo. Los campos electromagnéticos generados en el cerebro reflejan el estado cognitivo del paciente, viéndose afectados por enfermedades tales como la EA o la presencia de crisis epilépticas (Cummings *et al.*, 2004). La electroencefalografía y la magnetoencefalografía son técnicas no invasivas que permiten medir los campos electromagnéticos que se producen en el cerebro en tiempo real como consecuencia de su actividad neuronal (Cohen, 2017). Los registros MEG ofrecen una mejor resolución espacial y una menor distorsión de la actividad neuronal que los registros EEG, si bien su coste de adquisición es notablemente mayor (Rodríguez-González *et al.*, 2021). Aunque hay diferencias entre ambos tipos de registros, tanto EEG como MEG permiten la identificación de patrones de actividad cerebral, pudiéndose combinar las dos para mejorar el diagnóstico de determinados trastornos neurológicos (Sternickel y Braginski, 2006).

En este capítulo se van a analizar estas técnicas. Se comentará su historia y evolución, su procesado, y por qué se ha decidido en este TFG centrarse en MEG.

## 2.2. Historia y evolución de la tecnología

El físico británico Richard Caton fue el primero en intentar estudiar la actividad eléctrica del cerebro, y en 1875 consiguió extraer conclusiones de sus propiedades eléctricas en conejos, monos y perros (Brazier, 1961). Sin embargo, no fue hasta 1929 cuando el psiquiatra alemán Hans Berger realizó la primera observación de la actividad eléctrica del cerebro humano. Berger registró unos pocos minutos de actividad cerebral en un joven de 17 años mediante la colocación de dos electrodos, uno en la parte frontal y otro en la parte occipital del cráneo del paciente (Barwick, 1971). En las publicaciones de diversos artículos de Berger se realizó la primera descripción de la actividad eléctrica cerebral y sus alteraciones ante distintos estados fisiológicos o patológicos. Años más tarde, Berger identificó dos tipos de ondas en función de dos parámetros: las de mayor voltaje y menor frecuencia, que fueron denominadas ondas alfa, y las de menor voltaje y mayor frecuencia, que pasarían a llamarse ondas beta (Stevens, 1974). A partir de este descubrimiento, y aunque en los inicios Berger fuera tratado con escepticismo, el EEG se convirtió en el método

de diagnóstico clínico de enfermedades cerebrales con mayor potencial de la época. Permitió el estudio no invasivo de la electrofisiología cerebral antes de la introducción de la resonancia magnética (MRI, *Magnetic Resonance Imaging*). Este hecho se produjo en la década de 1980, y hasta entonces no se disponía de otras técnicas que permitiesen analizar la función del cerebro. Sin embargo, estaba limitada debido a los escasos recursos computacionales y la simplicidad de los modelos cerebrales de los que se disponía (Darcey *et al.*, 1980). Aún así, el EEG fue un descubrimiento que marcó un antes y un después en el avance de la neurociencia.

Por otro lado, el magnetismo en el cuerpo humano comenzó a tomar protagonismo cuando se pudo observar la desviación de la aguja de una brújula cuando los tejidos biológicos eran sometidos a algún tipo de estimulación eléctrica. Este hallazgo fue descubierto por Humphry Davy en 1832; sostenía que el campo magnético generado tenía una dirección perpendicular al campo eléctrico aplicado (Rampp y Stefan, 2007). Tiempo después, en 1968, el físico David Cohen evidenció la presencia de actividad alfa cerebral registrada en cuatro sujetos haciendo uso de un único sensor MEG (Cohen, 1968), y constató el grado de similitud existente entre las señales EEG y MEG. Sin embargo, no fue hasta mediados de los ochenta cuando la investigación e instrumentación de MEG evolucionó drásticamente; esto se debió en parte a la aportación de varios científicos y firmas comerciales, que hasta el momento no habían formado parte de este área de investigación (Wikswow Jr *et al.*, 1993). Fue John Clarke el impulsor del desarrollo de equipos de mayor precisión, consiguiendo mejorar la resolución espacial de las señales MEG obtenidas (Clarke, 1980). Finalmente, cabe destacar que aún a finales del siglo XX no se había consolidado MEG como técnica de diagnóstico neurofisiológico, a pesar de las diversas ventajas que presentaba (Maestú *et al.*, 1999), como se comentará en apartados posteriores. Actualmente, la práctica clínica ya cuenta con esta herramienta, y se espera que su continua evolución ayude a mejorar la comprensión de la función cerebral.

### 2.3. Adquisición y procesamiento de señales EEG y MEG

La detección temprana de trastornos neuronales viene limitada, en gran medida, por la adecuada obtención de señales e imágenes del cuerpo humano. El enfoque principal de esta sección será la descripción de la adquisición y procesamiento de dichas señales con las herramientas de registro EEG y MEG, técnicas no invasivas

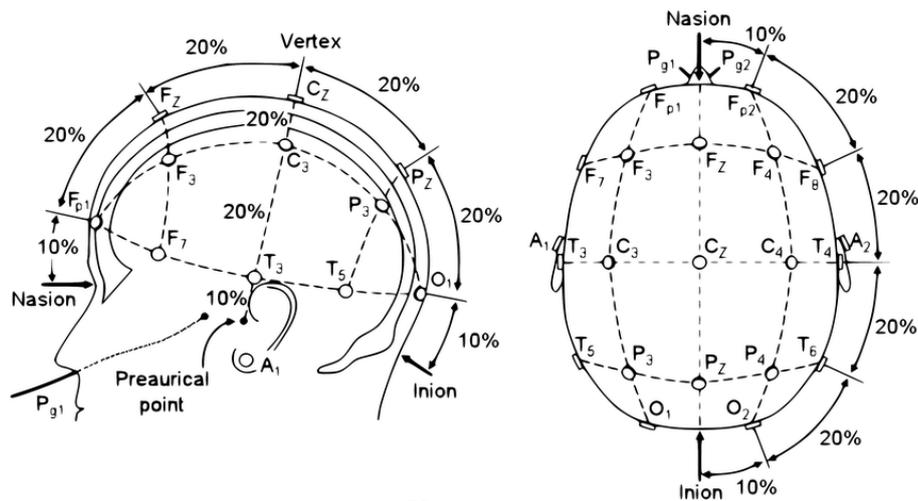
e indoloras (Cohen, 2017).

### 2.3.1. Señales EEG

Las señales EEG se obtienen mediante la colocación de varios electrodos en el cuero cabelludo una vez ha sido limpiado y preparado, evitando que cualquier sustancia pueda afectar la calidad de la señal registrada (Sanei y Chambers, 2013). Estos electrodos se colocan siguiendo diferentes estándares, como el sistema internacional 10-20, el 10-10 o el 10-5. Los números 20, 10 y 5 hacen referencia a la separación que hay entre los electrodos. Así, el 10-10 o el 10-5 permiten más colocar mayores posiciones. En la figura 2.1 se puede ver un ejemplo del sistema 10-20.

Para determinar la ubicación de dichos electrodos se utilizan dos puntos de referencia: uno situado en la parte superior de la nariz, denominado nasión, y otro en la parte posterior de la cabeza, conocido como inión. Una vez localizados, se miden las dimensiones longitudinales y transversales de la cabeza, y se dividen los perímetros resultantes en intervalos del 10 y del 20 % para el sistema 10-20. Finalmente, los electrodos se colocan de manera que se encuentren dentro de dichos intervalos cubriendo toda la superficie del cráneo de forma adecuada (Talamillo-García, 2011).

La principal función de los electrodos es registrar la actividad eléctrica en dife-



**Figura 2.1.** Sistema Internacional 10-20 para EEG (Sepúlveda *et al.*, 2015).

rentes áreas del cerebro y captar la diferencia de potencial entre ellos; un aumento del número de electrodos mejora la resolución espacial y aumenta la SNR (Ramos-Argüelles *et al.*, 2009). Posteriormente, la señal captada por dichos electrodos se amplifica, dado que la señal EEG obtenida es de muy baja amplitud, típicamente del orden de los microvoltios (Sanei y Chambers, 2013). Además, la baja conductividad eléctrica de las capas que debe atravesar la señal para ser captada desde el exterior dificulta su detección; para mejorar esta conductividad se suele aplicar un gel conductor en el cuero cabelludo, permitiendo la obtención de señales eléctricas con una mayor calidad (Talamillo-García, 2011).

Una vez se dispone de la señal EEG en bruto, el primer paso antes de proceder a analizarla consiste en llevar a cabo un filtrado, dado que no se va a tratar de una señal limpia, sino que va a contener ruido y artefactos que disminuyen su calidad y dificultan el diagnóstico (Bashashati *et al.*, 2007). Posteriormente, la señal puede fragmentarse en segmentos de menor duración para ser más preciso en el análisis y centrarse en diferentes momentos del registro (Huan y Palaniappan, 2004). A continuación, se extraen las características más relevantes de la señal, como su amplitud, frecuencia o forma de onda, estableciendo una serie de patrones de actividad cerebral asociados a posibles patologías. Finalmente, tras aplicar otra serie de análisis, como de dinámica o de conectividad, es posible interpretar la señal, combinando la información generada en cada uno de los pasos, y extraer conclusiones que puedan facilitar el diagnóstico posterior (Lotte *et al.*, 2007).

### 2.3.2. Señales MEG

Los sensores que obtienen las señales MEG son capaces de registrar la actividad magnética generada en la superficie de la cabeza y que acompaña a las señales eléctricas medidas con EEG. Dado que los campos magnéticos producidos son mucho más débiles que los campos eléctricos asociados, se debe hacer uso de un dispositivo que permita captar con suficiente potencia la actividad magnética cerebral. Estos dispositivos son los SQUID, unos instrumentos extremadamente sensibles basados en el fenómeno cuántico de la superconducción (Vrba y Robinson, 2001). Los sistemas de registro MEG actuales pueden hacer uso de más de 300 sensores SQUID con una separación de aproximadamente 2 cm respecto al cuero cabelludo (Zhang *et al.*, 2014).

La medición de señal MEG se puede hacer con el sujeto sentado o tumbado; posteriormente, se le introduce la cabeza en el casco de registro y se procede a regis-

trar las señales magnéticas mediante el conjunto de gradiómetros o magnetómetros distribuidos por el casco. Este sistema de captación aumenta la eficiencia en la detección de las señales dado que son poco sensibles ante la presencia de ruido ambiental (Sternickel y Braginski, 2006). Después, las señales son transformadas en impulsos eléctricos mediante el anillo del SQUID, para luego ser procesadas y llevar a cabo su posterior análisis (Maestú *et al.*, 1999).

Los SQUID operan a temperaturas cercanas al cero absoluto, lo que requiere que sean sumergidos en sustancias criogénicas, como el helio líquido, para conservar sus propiedades superconductoras (Sternickel y Braginski, 2006). Además, es esencial proporcionar un buen aislamiento magnético para evitar interferencias y ruido que puedan afectar la calidad de la señal medida. Esto se puede lograr mediante la utilización de salas aisladas magnéticamente, donde los campos magnéticos producidos por instrumentos de laboratorio, ascensores o vehículos no afecten la medición de la señal (Poza Crespo, 2008).

El procesamiento de la señal MEG es muy similar al de EEG; involucra etapas tales como el filtrado de la señal, técnicas de detección de artefactos visuales o reducción del ruido ambiental (Sternickel y Braginski, 2006). En muchas ocasiones, resulta conveniente registrar la señal EEG al mismo tiempo que la MEG pues, combinándolas, se pueden extraer características importantes que no se obtienen con ninguna de ellas por separado.

### 2.4. Ventajas y desventajas de EEG y MEG

Son muchas las técnicas empleadas para registrar las señales generadas por el cerebro, desde los ultrasonidos, las MRI o la tomografía por emisión de positrones (PET), además del EEG y el MEG. Este TFG se centra en estas dos últimas herramientas debido a la buena resolución temporal que ofrecen (Sanei y Chambers, 2013), además de ser no invasivas y no dolorosas para el paciente. Sin embargo, MEG presenta una serie de características beneficiosas para el correcto funcionamiento de la herramienta diseñada en este TFG que merecen ser mencionadas.

A pesar de que el paciente deba permanecer inmóvil mientras se adquiere el registro MEG y sea una técnica mucho más costosa que EEG, una de las principales ventajas que presenta es que no existe una distorsión aparente debida a la conducción de volumen en las señales MEG medidas en los sensores y el cuero cabelludo; esto dota a MEG de mayor sensibilidad para reflejar la actividad de las fuentes neuronales

que han dado lugar a la actividad MEG (Hari, 2004). Además, en comparación con EEG, ofrece una mejor resolución espacial. Asimismo, es más sencillo de utilizar, ya que la MEG mide los campos magnéticos en valor absoluto, mientras que la EEG mide la diferencia de potencial entre dos puntos de la cabeza (Hämäläinen *et al.*, 1993).

Dado que el objetivo principal de este TFG consiste en la detección y clasificación de artefactos en señales neuronales, la precisión espacial requerida es de vital importancia para localizar fácilmente las fuentes de actividad cerebral, ayudando a identificar el origen de los artefactos y tenerlos en consideración para evitar su aparición en mediciones futuras. Por eso, en una aproximación inicial, se ha optado por desarrollar la herramienta de detección en base a registros MEG.

### 2.5. Limitaciones y desafíos en la interpretación de MEG

MEG es una técnica de neuroimagen que ha tenido un gran impacto en la medicina clínica durante los últimos años (Rodríguez-González *et al.*, 2021). No obstante, su interpretación presenta una serie de limitaciones y desafíos que pueden sesgar el diagnóstico de enfermedades o condiciones neuronales en los pacientes que se someten a este tipo de prueba.

Uno de los principales condicionantes consiste en la gran cantidad de información que genera, debido a la gran cantidad de canales de registro de que se dispone. Además, un registro MEG puede derivar de muchas configuraciones de fuentes cerebrales, por lo que la localización de fuentes no tiene una sino varias soluciones posibles (Hari *et al.*, 2000). Existen diferentes modelos que permiten maximizar la probabilidad estadística que determina dónde puede encontrarse la fuente de actividad cerebral (Escalona-Vargas, 2014): el modelo de dipolos y el modelo de fuentes linealmente distribuidas. El primero se basa en la configuración de una o varias fuentes, estimando su ubicación y midiendo el campo magnético generado para después reajustar la posición minimizando la diferencia entre el campo magnético estimado y el medido, reduciendo progresivamente el error residual. El segundo considera que la actividad cerebral se distribuye sobre todas las posibles ubicaciones de fuentes, consiguiendo que no sea necesario contar con información de antemano acerca de la posición de cada una de las fuentes (Zhang *et al.*, 2014).

La sensibilidad de MEG para cuantificar la actividad de las fuentes neuronales

es otro aspecto clave a tener en cuenta. Al ser elevada, permite detectar los campos generados en las capas más profundas del cerebro, dotando de información adicional que no proporciona el EEG, lo cual supone una ventaja en cuanto a la precisión en la localización de fuentes (Ahlfors *et al.*, 2010). Sin embargo, la alta sensibilidad hace que el paciente no pueda moverse mientras se le está practicando un registro, puesto que también es sensible a movimientos corporales, así como a campos magnéticos externos, limitando la calidad de la señal, e imponiendo la necesidad de disponer de una sala aislada magnéticamente (Poza Crespo, 2008).

Por último, una de las cuestiones con mayor relevancia en el estudio e interpretación de señales MEG es la presencia de artefactos, *i. e.*, componentes no deseadas que interfieren en la señal y la distorsionan. A la hora de llevar a cabo un registro MEG, es importante evitar la aparición de artefactos o eliminarlos durante la etapa de preprocesamiento una vez registrada la señal (Carr y Brown, 2001). En este sentido, los sujetos que componen la base de datos que se ha empleado para desarrollar este TFG se encontraban en estado de reposo y con los ojos cerrados. Esto ha permitido minimizar la presencia de dichos artefactos, aunque seguían estando presentes en las señales obtenidas.

A pesar de las limitaciones expuestas, se considera que las ventajas que ofrece MEG son significativas y compensan sus desventajas.

---

# Capítulo 3

## Artefactos en señales neuronales

### Índice

---

3.1. Introducción . . . . .	32
3.2. Impacto de la presencia de artefactos . . . . .	36
3.3. Técnicas de detección de artefactos en señales de actividad cerebral . . . . .	38
3.4. Aplicaciones de la Inteligencia Artificial en la detección de artefactos . . . . .	39

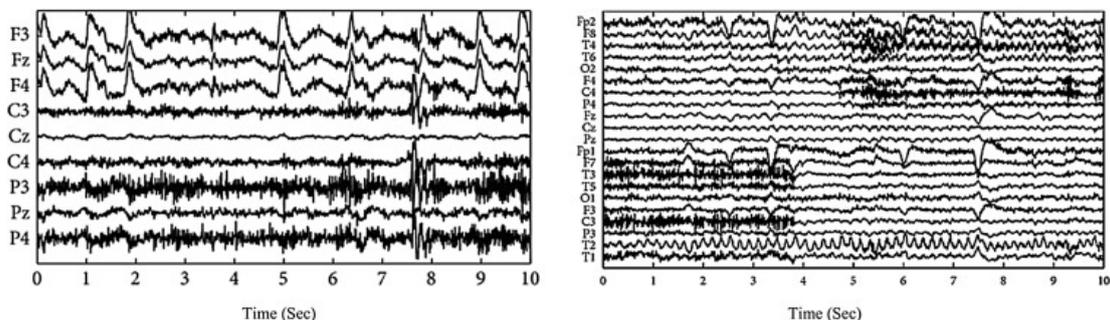
---

## 3.1. Introducción

El ruido es un fenómeno omnipresente con el que convivimos todos los días, desde una mezcla confusa de sonidos en la calle, donde coexisten personas, vehículos, animales, etc., hasta un conjunto de señales extrañas e indeseadas que interrumpen una comunicación, como las interferencias que pueden surgir durante una llamada telefónica o las que dificultan la comunicación entre un avión y una torre de control. Uno de los campos que se ha visto afectado por este ruido es el de la neurociencia. Las señales neuronales son utilizadas en una amplia gama de aplicaciones, desde el análisis de imágenes para el diagnóstico médico hasta la identificación de patrones cerebrales asociados a una posible patología (Mahmud y Vassanelli, 2016). En este sentido, los sistemas que permiten la obtención de señales biomédicas son altamente sensibles al ruido, cuyas características espacio-temporales son, en ocasiones, muy similares a las propias de las señales neuronales objeto de estudio. Por lo tanto, su eliminación o filtrado mediante la aplicación de métodos tradicionales se ve perjudicado (Mahmud *et al.*, 2012).

Los tipos de ruido que se cuelan en la señal, comúnmente conocidos como artefactos, se originan en diferentes fuentes. Pueden ser fisiológicos, generados por el propio paciente al cual se le está practicando un registro de actividad neuronal, o no fisiológicos, causados por elementos externos al paciente (Fabietti *et al.*, 2020). El primer paso en la eliminación de estos artefactos indeseados implica la necesidad de identificarlos y distinguirlos de la propia señal cerebral. En la figura 3.1 se puede apreciar una señal EEG contaminada con artefactos de diversos orígenes (Islam *et al.*, 2016).

Dentro de los artefactos fisiológicos, los más frecuentes son los de origen car-

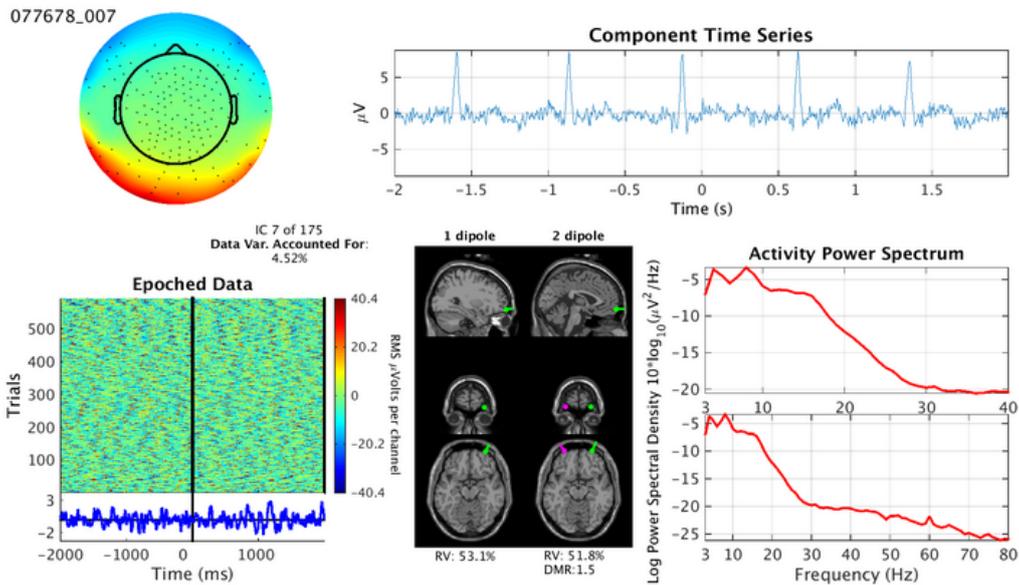


**Figura 3.1.** Izquierda: 10 segundos de señal EEG contaminada con artefactos musculares. Derecha: 21 canales contaminados con actividad ocular y muscular (Islam *et al.*, 2016).

### 3 Artefactos en señales neuronales

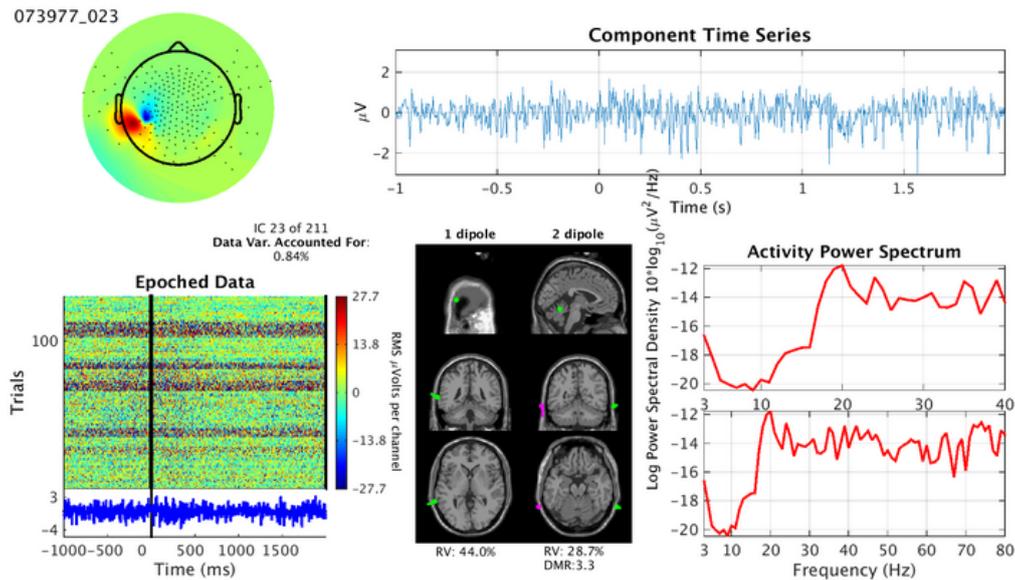
díaco, muscular, ocular y, en menor medida, los de actividad respiratoria y de la transpiración (ICL, 2023; Team, 2023):

- Actividad cardíaca. La actividad cardíaca, también conocida como electrocardiograma (ECG), deriva de los potenciales eléctricos generados por el corazón. Dicha señal se suele localizar en frecuencias bajas. En el dominio temporal, esta señal se comporta de manera rítmica debido a los latidos del corazón del paciente, tal y como puede verse en la figura 3.2.
- Actividad muscular. La electromiografía (EMG), o la actividad muscular, se origina debido a la actividad eléctrica producida por los músculos. Dicha señal es significativamente más intensa que la señal MEG, y se ubica en frecuencias altas, superiores a los 20 Hz. Además, la amplitud de la señal neuronal en el dominio del tiempo se ve afectada por la considerable potencia de este artefacto. En la figura 3.3 se puede apreciar un ejemplo de señal contaminada con este tipo de artefacto.



**Figura 3.2.** Componente ICA asociada a actividad cardíaca recogida en un registro EEG. Esquina superior izquierda: topografía de la cabeza donde se representa la posición de los electrodos, en rojo la parte que más contribuye en la generación del artefacto cardíaco y en azul la que menos. A su derecha: señal en el dominio del tiempo. Esquina inferior izquierda: potencia de la componente durante todo el registro. A su derecha: localización de fuentes estimada que mejor se aproximan a la topografía calculada. Esquina inferior derecha: señal en el dominio de la frecuencia (ICL, 2023).

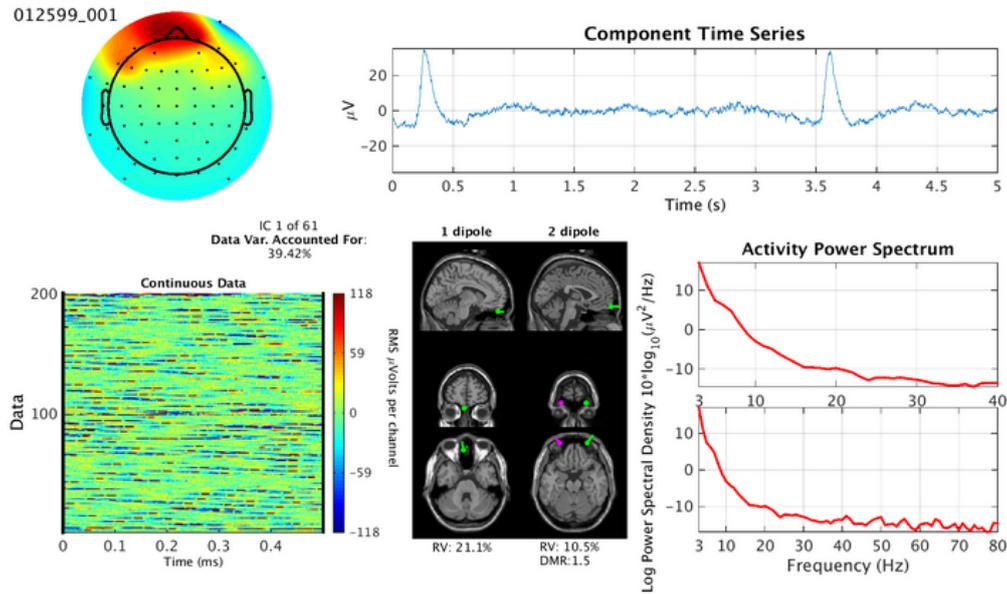
### 3 Artefactos en señales neuronales



**Figura 3.3.** Componente ICA asociada a actividad muscular. Esquina superior izquierda: topografía de la cabeza donde se representa la posición de los electrodos, en rojo la parte que más contribuye en la generación del artefacto muscular y en azul la que menos. A su derecha: señal en el dominio del tiempo. Esquina inferior izquierda: potencia de la componente durante todo el registro. A su derecha: localización de fuentes estimada que mejor se aproximan a la topografía calculada. Esquina inferior derecha: señal en el dominio de la frecuencia (ICL, 2023).

- Actividad ocular. La actividad ocular o electrooculograma (EOG), surge de los parpadeos o de los movimientos de los ojos. Este tipo de señal se registra en la parte frontal de la cabeza, próxima a los ojos del paciente. Su potencia está concentrada en bajas frecuencias, por debajo de los 5 Hz, y tiene una amplitud generalmente de un orden de magnitud superior al de la señal MEG, tal y como se puede ver en la figura 3.4.
- Actividad respiratoria. Este tipo de artefactos podrían formar parte del grupo de los de actividad muscular, dado que se considera que son producidos por movimientos del pecho o de la cabeza cuando el paciente respira. No son muy comunes si el sujeto se encuentra sentado y, en caso de que estuviera tumbado, podrían deberse a los movimientos de los electrodos al inhalar y exhalar.
- Actividad transpiratoria. La transpiración del cuerpo humano hace que las pequeñas gotas de sudor generadas por las glándulas sudoríparas provoquen cambios en las señales detectadas por los electrodos. Su localización también resulta complicada, aunque suelen encontrarse en bajas frecuencias.

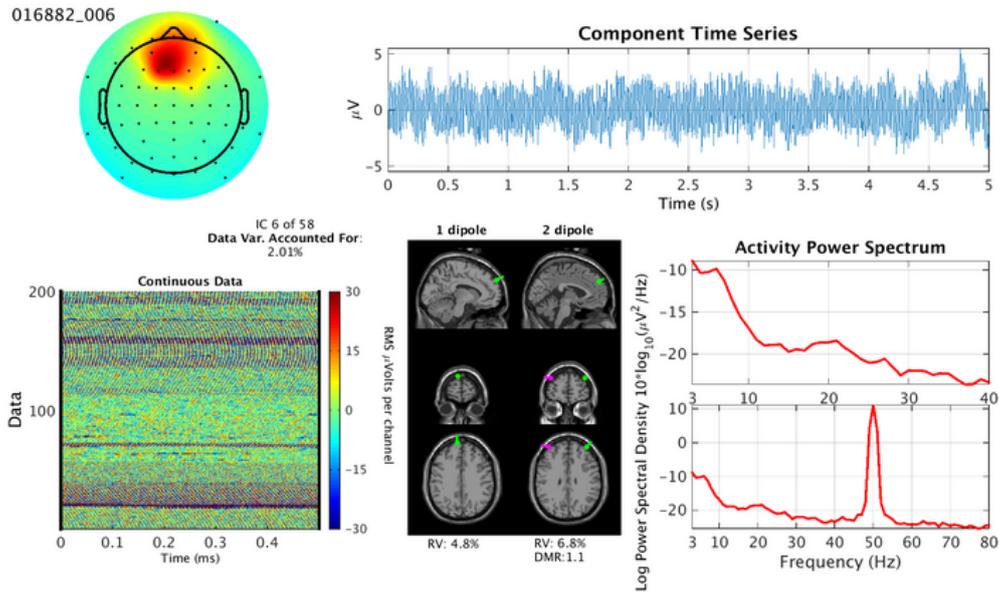
### 3 Artefactos en señales neuronales



**Figura 3.4.** Componente ICA asociada a actividad ocular. Esquina superior izquierda: topografía de la cabeza donde se representa la posición de los electrodos, en rojo la parte que más contribuye en la generación del artefacto ocular y en azul la que menos. A su derecha: señal en el dominio del tiempo. Esquina inferior izquierda: potencia de la componente durante todo el registro. A su derecha: localización de fuentes estimada que mejor se aproximan a la topografía calculada. Esquina inferior derecha: señal en el dominio de la frecuencia (ICL, 2023).

Por otro lado, los artefactos no fisiológicos con los que uno puede encontrarse son debidos a la red eléctrica, al movimiento de los electrodos o la incorrecta disposición de estos, a movimientos del cableado o a interferencias electromagnéticas. Los primeros son causados por la corriente alterna que alimenta los dispositivos electrónicos que se encuentran en la sala de medición. Este tipo de artefactos son los más fácilmente detectables, dado que en el dominio de la frecuencia aparece un pico situado en 50 o 60 Hz, frecuencia a la cual operan las redes de distribución de electricidad en el mundo. En la figura 3.5 se puede ver un ejemplo de este tipo de artefacto. El resto pueden considerarse como “otros”, dado que no tienen un patrón identificable y, normalmente, se encuentran mezclados con otro tipo de señales ruidosas inusuales o insignificantes.

### 3 Artefactos en señales neuronales



**Figura 3.5.** Componente ICA asociada a la red eléctrica. Esquina superior izquierda: topografía de la cabeza donde se representa la posición de los electrodos, en rojo la parte que más contribuye en la generación del artefacto asociado a la red eléctrica y en azul la que menos. A su derecha: señal en el dominio del tiempo. Esquina inferior izquierda: potencia de la componente durante todo el registro. A su derecha: localización de fuentes estimada que mejor se aproximan a la topografía calculada. Esquina inferior derecha: señal en el dominio de la frecuencia.

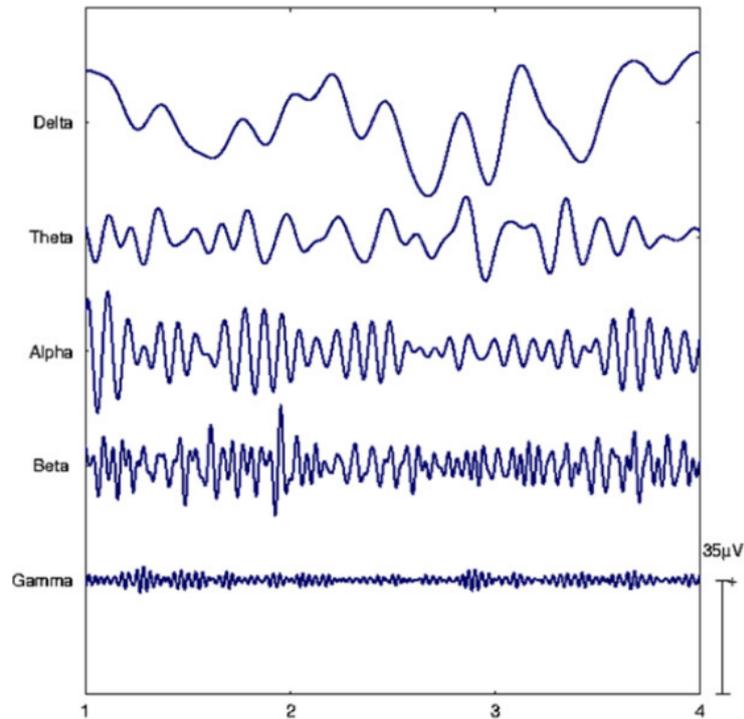
### 3.2. Impacto de la presencia de artefactos

Las señales provenientes de los registros EEG y MEG son de muy baja potencia y están concentradas en un cierto rango de frecuencias, como ya se ha indicado previamente; por ejemplo, la mayor parte de la energía en un registro EEG o MEG se concentra en el rango inferior del espectro (Daly *et al.*, 2012). Los ritmos neuronales se clasifican en cinco bandas de frecuencia diferentes: delta, situada a bajas frecuencias (entre 0.5 y 4 Hz); zeta, comprendida en el intervalo de 4 a 8 Hz; alfa, entre los 8 y los 13 Hz; beta, entre 13 y 30 Hz; y gamma, con oscilaciones de más de 30 Hz. La segmentación de las señales neuronales en estas bandas es útil para obtener características que reflejen el estado cognitivo del paciente (Sanei y Chambers, 2013). En la figura 3.6 se pueden ver señales EEG correspondientes a estas cinco bandas con los niveles de amplitud más comunes que suelen presentar.

Las señales neuronales son tratadas como estocásticas, dado que es imposible conocer *a priori* cuál va a ser su amplitud, duración o morfología (Sörnmo y Laguna, 2005); además, los artefactos aumentan esta incertidumbre, debido a sus distintas

### 3 Artefactos en señales neuronales

---

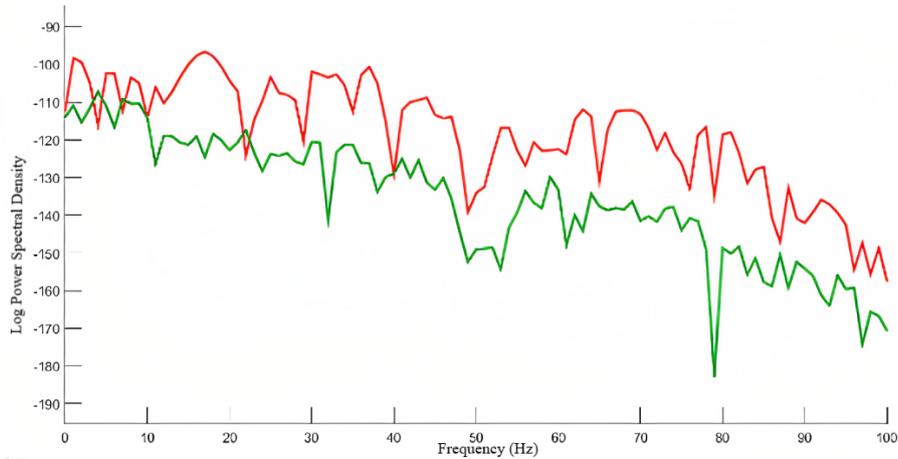


**Figura 3.6.** Señales EEG en las cinco bandas de frecuencia convencionales utilizadas en estudios neurofisiológicos (Sanei y Chambers, 2013).

configuraciones según el tipo de artefacto y paciente, disminuyendo la probabilidad de obtener una señal cerebral pura. En el dominio de la frecuencia, el espectro calculado se ve distorsionado debido a la presencia de los artefactos, que pueden originar componentes de frecuencia que no son generadas por actividad neuronal.

La figura 3.7 representa dos segmentos de una señal EEG utilizados para estimar la función de densidad espectral de potencia o PSD (*Power Spectral Density*), que permite observar la distribución de la potencia de la señal en el dominio de la frecuencia (Poza Crespo, 2008).

El impacto significativo que tienen los artefactos en las señales neuronales afecta a la calidad y la precisión de los datos registrados; por lo tanto, resulta de vital importancia recurrir a técnicas que permitan su eliminación para garantizar la correcta interpretación de la actividad cerebral que está siendo analizada.



**Figura 3.7.** Estimación de la PSD. En rojo la señal EEG con artefactos, en verde la señal EEG sin artefactos (Zangeneh Soroush *et al.*, 2022).

### 3.3. Técnicas de detección de artefactos en señales de actividad cerebral

Identificar la presencia de artefactos es complicado y muchas veces la componente ruidosa es confundida con la propia señal neuronal o viceversa, es decir, un artefacto es tratado como un patrón de actividad cerebral. Además, en muchas aplicaciones es importante conservar la mayor cantidad de señal neuronal posible para poder disponer de la máxima cantidad de información a la hora de llevar a cabo los análisis. El filtrado de la señal es una de las técnicas clásicas de eliminación de ruido más utilizada, pero resulta no ser efectivo cuando la banda de frecuencias en la que se concentra el ruido coincide con la propia de la señal neuronal (Sweeney *et al.*, 2012); también podría llevarse a cabo un promediado de los datos obtenidos, donde se consigue eliminar el ruido y mantener la señal sincronizada con los diferentes estímulos, excepto cuando los artefactos están también sincronizados con dichos estímulos (Kawakatsu, 2003). Por lo tanto, hace falta disponer de otras técnicas que aseguren la supresión de las señales indeseadas.

La transformada Wavelet (WT, *Wavelet Transform*) es una técnica que, aplicada a la señal EEG o MEG, permite obtener una mejor resolución temporal para las componentes de alta frecuencia y una mejor resolución frecuencial para las de baja frecuencia. Esto resulta beneficioso dado que las señales neuronales presentan diferentes comportamientos en distintos rangos de frecuencia, como ya se ha comentado previamente. Esa buena resolución, tanto temporal como frecuencial, se consigue

mediante la descomposición de la señal en diferentes escalas, y permite eliminar aquellas en las que se concentra el ruido. Así, esta herramienta permite identificar y filtrar los artefactos (Azzarboni *et al.*, 2004). No obstante, esto puede derivar en una pérdida significativa de la información, y los resultados obtenidos pueden ser difíciles de interpretar.

Por otro lado, un método ampliamente utilizado hoy en día procede de la separación de las señales EEG o MEG en componentes independientes, correspondientes a las diferentes fuentes que generan la señal obtenida. Esta técnica se conoce como ICA, e implica que no existe correlación espacial, temporal o frecuencial entre las formas de onda generadas, además de suponer independencia estadística entre las fuentes (Urigüen y Garcia-Zapirain, 2015); aunque esta última suposición puede no ser cierta en algunos casos. Cabe destacar que en muchas ocasiones se complementa su uso con alguna otra técnica de detección de artefactos para conseguir resultados más precisos, dado que ICA no realiza una clasificación de componentes. En este sentido, un técnico especializado se suele encargar de visualizar cada una de las fuentes determinando aquellas componentes artefactuadas, clasificándolas y procediendo a su eliminación.

Existe una gran variedad de métodos de preprocesamiento estandarizados, aparte de los ya mencionados, que permiten obtener una señal EEG o MEG limpia, prácticamente sin artefactos (Tahir-Akhtar M., 2012) (Mijović *et al.*, 2010); sin embargo, actualmente no se dispone de ninguno que garantice la completa eliminación de dichos artefactos y determine la calidad de la señal de forma objetiva (Team, 2023).

#### 3.4. Aplicaciones de la Inteligencia Artificial en la detección de artefactos

Gracias a Internet y al hecho de disponer de ordenadores cada vez más potentes ha sido posible desarrollar análisis de datos a gran escala por medio de herramientas software que facilitan la tarea, proporcionando resultados fiables y objetivos en un corto período de tiempo. En conjunción con todo ello, los métodos automáticos de análisis y clasificación han supuesto un antes y un después en el ámbito de la biomedicina, donde la inteligencia artificial ha permitido analizar grandes cantidades de datos en un tiempo razonable, garantizando la precisión de los resultados obtenidos y minimizando el error humano.

### 3 Artefactos en señales neuronales

---

Uno de los campos que más se ha visto beneficiado es el de la neurociencia donde, gracias a estas nuevas herramientas, se han abordado los problemas que surgen en la detección y eliminación de artefactos en señales neuronales cuando la clasificación se lleva a cabo de forma manual. Una de las herramientas automáticas empleadas hasta la fecha se trata de MARA (*Multiple Artifact Rejection Algorithm*), un software de código abierto incluido en el *toolbox* EEGLAB que permite automatizar el proceso de etiquetado manual de artefactos empleando el algoritmo de *Machine learning* (ML) (Haresign *et al.*, 2021). A partir de una clasificación previa por parte de los expertos, MARA aprende de dichas clasificaciones, extrayendo características del dominio espacial, temporal y espectral de las señales. Además, MARA clasifica componentes ICA, lo que permite una disgregación entre componentes artefactuadas y no artefactuadas. Sin embargo, uno de los problemas que presenta MARA es que no ofrece resultados demasiado fiables cuando la cantidad de artefactos presentes en un registro es muy densa, por ejemplo, cuando dicho registro procede de un niño de corta edad, o cuando los artefactos se sitúan por encima de los 20 Hz, dado que este software está entrenado con datos que han sido previamente filtrados paso-bajo justo a esa frecuencia (Haresign *et al.*, 2021).

Otro software que se ha desarrollado es *Autoreject*, que consiste en una herramienta automática de eliminación de artefactos en datos provenientes de señales EEG y MEG que, además, permite la reparación de ensayos erróneos en dichas señales. Está basada en validación cruzada y en la estimación del umbral óptimo de pico a pico. Esta última estima un umbral para cada sensor, identificando sensores afectados por intervalo temporal analizado. Posteriormente, se seleccionan los sensores que pueden producir esos datos indeseados, y se repara la prueba mediante interpolación o exclusión de dichos sensores para los análisis posteriores. Sin embargo, dado que el resultado ofrecido por cada uno de los sensores es diferente, la decisión tomada sobre uno puede perjudicar a otro, haciendo que se pierda información importante propia de la señal neuronal. Esto conlleva que se deban tener en cuenta otras consideraciones a la hora de emplear esta herramienta, como por ejemplo combinarlo con ICA o con una inspección visual por parte de un técnico (Jas *et al.*, 2017).

ICLabel constituye otra de las herramientas empleadas para la clasificación automática de componentes ICA. Hace uso de una red neuronal artificial entrenada sobre una base de datos formada por 6000 registros EEG, a los cuales se les ha aplicado ICA y se les ha incorporado la información correspondiente a la localización de sus

### 3 Artefactos en señales neuronales

---

fuentes. La gran cantidad de señales de que dispone la hace mucho más precisa a la hora de llevar a cabo una clasificación. No obstante, las imprecisiones en los mapas topográficos ofrecidos por ICLabel, y que son debidas a las diferencias de potencial entre los electrodos, hacen que la precisión en la clasificación se vea limitada (Sasaki *et al.*, 2019).

Estas dos herramientas están basadas en ML. Sin embargo, las técnicas DL han superado en muchos ámbitos al ML, dado que se pueden conseguir resultados más precisos en tareas de reconocimiento de patrones, como sucede en el etiquetado de componentes ICA (O'Shea y Nash, 2015).

---

# Capítulo 4

## Redes Neuronales Convolucionales

### Índice

---

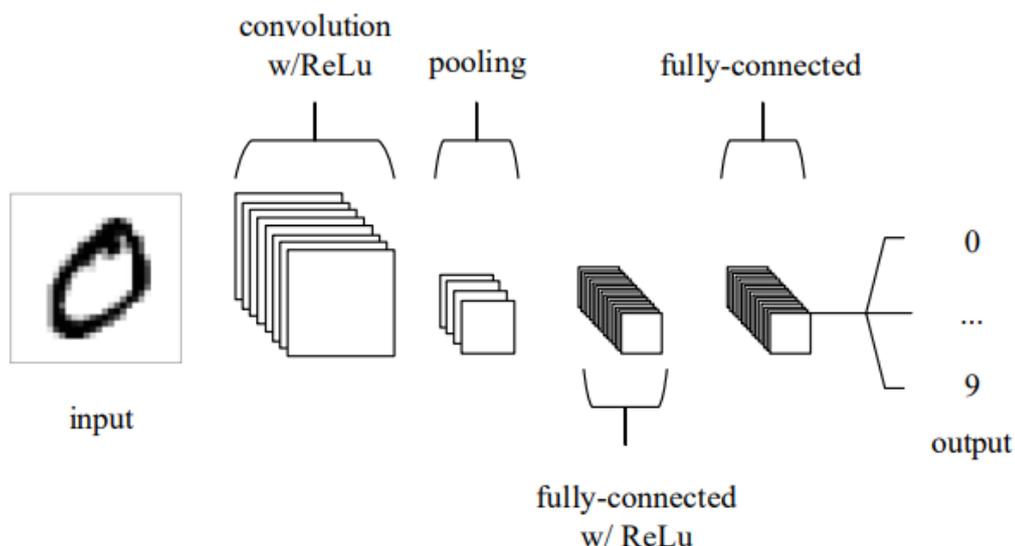
4.1. Introducción . . . . .	43
4.2. Métodos de entrenamiento y optimización . . . . .	44

---

### 4.1. Introducción

Las Redes Neuronales Artificiales (ANN, *Artificial Neural Networks*) constituyen una técnica de AI que procesa y clasifica la información basándose en el funcionamiento del cerebro humano, donde se interconectan miles de millones de neuronas por medio de la sinapsis. Gracias a este proceso, las neuronas son capaces de combinar las distintas señales que reciben, consiguiendo un cierto nivel de activación y emitiendo otras señales en función de las primeras (Antona-Cortés, 2017). Las ANN imitan este comportamiento haciendo uso de neuronas artificiales, también denominadas nodos. Esto son modelos matemáticos que hacen uso de ecuaciones y algoritmos emulando el funcionamiento de las neuronas biológicas.

Uno de los tipos de ANN son las CNN, que se emplean para resolver tareas complejas de reconocimiento de patrones, centrándose en el tipo de entrada en lugar de en la totalidad del problema para conseguir reducir el número de parámetros empleados en una ANN (O’Shea y Nash, 2015). Se denominan convolucionales porque están formadas por múltiples filtros convolucionales de diversas dimensiones. Las CNN están formadas por diferentes capas, entre las que se incluyen las de entrada, las convolucionales, las de *pooling*, las que se encuentran completamente conectadas, y las de salida. En la figura 4.1 se puede ver un ejemplo de una CNN que incluye todas estas capas mencionadas.



**Figura 4.1.** Arquitectura simple de una CNN formada por 5 capas (O’Shea y Nash, 2015).

## 4 Redes Neuronales Convolucionales

---

La capa de entrada contiene los datos del objeto de la medición que se desea clasificar, y la CNN calculará el producto escalar entre un filtro denominado *kernel* y un fragmento de esos datos de entrada para extraer sus características más relevantes, como bordes, texturas y patrones. Por otro lado, la capa de *pooling* reduce el tamaño de las características extraídas submuestreando los datos que le llegan y, finalmente, las que se encuentran completamente conectadas llevan a cabo una clasificación de la información extraída, permitiendo identificar objetos en una imagen o clasificarla en diferentes categorías (O'Shea y Nash, 2015).

Cada capa de una CNN hace uso de una serie de pesos que se ajustan durante el entrenamiento de la red, extrayendo características relevantes de los datos de entrada y clasificándolos de manera precisa. Así, el primer nivel jerárquico aprende información de la entrada, y se la envía al siguiente nivel. Este compondrá información más compleja a partir de esos datos que ha recibido, y se los pasará al tercer nivel, y así sucesivamente hasta completar todas las capas (Ros-García, 2019). A partir de la modificación de los pesos correspondientes a cada una de las conexiones es posible obtener la salida deseada.

Las redes neuronales aprenden de la experiencia a través de ejemplos de los que extraen las características principales para, posteriormente, generalizar en ejemplos nuevos lo aprendido de los anteriores.

### 4.2. Métodos de entrenamiento y optimización

Antes de comenzar con la predicción de resultados, las CNN deben someterse a un proceso de entrenamiento, donde se ajustarán los pesos de las interconexiones minimizando el error producido en cada iteración o época. Una vez conseguidos los valores deseados, se introducen los datos de validación, que determinarán si el proceso de entrenamiento ha concluido en función de los resultados obtenidos a partir de ellos. Dado que una CNN puede llegar a memorizar el conjunto de entrenamiento, provocando un correcto funcionamiento en dicha etapa, pero fallando en ejemplos nunca antes vistos durante el proceso de validación, es necesario escoger un conjunto de datos lo suficientemente generales. Así, se podrá ver la evolución de la generalización del entrenamiento con datos que no han sido utilizados para actualizar el valor de los pesos tras cada época. Por lo tanto, si la predicción es correcta, se da por finalizada esta etapa; en cambio, si los datos introducidos durante el entrenamiento no fueron idóneos, provocando que la red sea incapaz de generalizar

## 4 Redes Neuronales Convolucionales

---

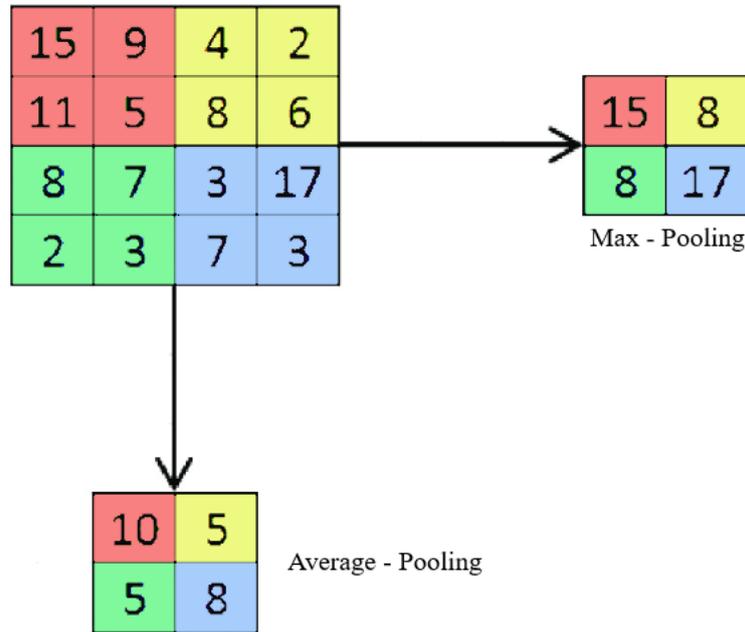
(situación que se conoce como sobreentrenamiento u *overfitting*), habrá una falta de precisión en la validación (O'Shea y Nash, 2015).

A la hora de diseñar la arquitectura de una CNN, son varios los aspectos que deben tenerse en cuenta. Para entrenar estas redes correctamente y ajustar sus pesos de manera que aprendan de forma eficiente y ofrezcan resultados precisos, se emplean diferentes técnicas de entrenamiento y optimización. En una primera aproximación, es importante decidir los distintos hiperparámetros como capas ocultas con las que se va a contar, así como el número de neuronas de las que va a disponer el modelo planteado. Esto va a depender del problema específico que se pretenda resolver y de la cantidad de datos disponibles para el entrenamiento, si bien es preferible emplear el menor número de capas posibles (Hornik, 1991).

Para generar los pesos mencionados previamente y ajustarlos al problema que se quiere resolver, se va a hacer uso de optimizadores. Estos calcularán el gradiente de la función de coste para cada peso, es decir, la derivada parcial de la diferencia entre la predicción y el valor real correspondiente, con el fin de minimizar dicho error. Hay diversas funciones de optimización, pero en este TFG se ha empleado una denominada *Adam* (*Adaptive moment estimation*), que combina la técnica *AdaGrad* (*Adaptive Gradient algorithm*) con la *RMSProp* (*Root Mean Square Propagation*). La primera adapta el valor de entrenamiento inicial a cada uno de los pesos con respecto al gradiente acumulado en cada iteración, y la segunda realiza algo similar pero dividiendo el factor de entrenamiento entre la media del declive exponencial del cuadrado de los gradientes (Taqi *et al.*, 2018).

En cuanto a las diferentes capas que forman la red, la de convolución genera una nueva matriz de salida (*i.e.*, una nueva capa de neuronas) tras haber realizado un producto escalar entre la matriz de entrada y una matriz denominada *kernel*, cuyo tamaño puede variar en función del problema que se desea resolver. Además, se puede elegir el número de elementos que se desplaza el *kernel* en cada paso de la convolución, consiguiendo resultados más reducidos cuanto mayor sea el salto (Hornik, 1991). Esta operación se repite reiteradas veces y, posteriormente, se aplica una función de activación específica, que determinará si la información recibida por cada neurona es relevante o no en el proceso de aprendizaje. Las funciones de activación más comunes son la sigmoide, la rectificadora (ReLU), la tangente hiperbólica (Tanh) y la softmax (Ertam y Aydın, 2017).

Tras la capa de convolución, viene la de *pooling* que, como se ha comentado previamente, permite llevar a cabo una reducción del volumen de datos, realizando



**Figura 4.2.** *Average-Pooling* y *Max-Pooling* en una matriz 4x4 aplicando una ventana de 2x2.

operaciones en regiones pequeñas de la matriz de entrada. Se distinguen dos modos de realizar este proceso, el *Average-Pooling* y el *Max-Pooling*. El primero calcula la media de los valores de una ventana de la matriz de entrada y el resultado se utiliza como valor de salida, mientras que el segundo toma el máximo de la ventana de la matriz de entrada (Ertam y Aydın, 2017). En la figura 4.2 se puede ver un ejemplo de una matriz, a la cual se le han aplicado los dos tipos de *pooling* mencionados, haciendo uso de una ventana de 2x2.

---

# Capítulo 5

## Materiales y Métodos

### Índice

---

5.1. Introducción . . . . .	48
5.2. Base de datos . . . . .	48
5.3. Diseño y desarrollo de un detector automático de arte- factos basado en <i>Deep Learning</i> . . . . .	51
5.3.1. Configuración de la red EEG-Inception . . . . .	51
5.3.2. Métricas de evaluación . . . . .	54
5.3.3. Modelos de clasificación . . . . .	58
5.3.4. Re-evaluación de las componentes . . . . .	59

---

### 5.1. Introducción

En este capítulo se explica la base de datos empleada para el desarrollo de la herramienta propuesta en este TFG, así como la metodología empleada para su análisis. Se ofrece una explicación detallada de la herramienta diseñada y se presenta la red junto con los hiperparámetros que la forman. Finalmente, se comentan los dos tipos de clasificación que se han llevado a cabo.

### 5.2. Base de datos

Los datos empleados proceden de un total de 473 sujetos, que fueron debidamente informados y autorizaron el uso de sus datos antes de proceder al registro. Este fue realizado en el Hospital Hokuto (Obihiro, Japón).

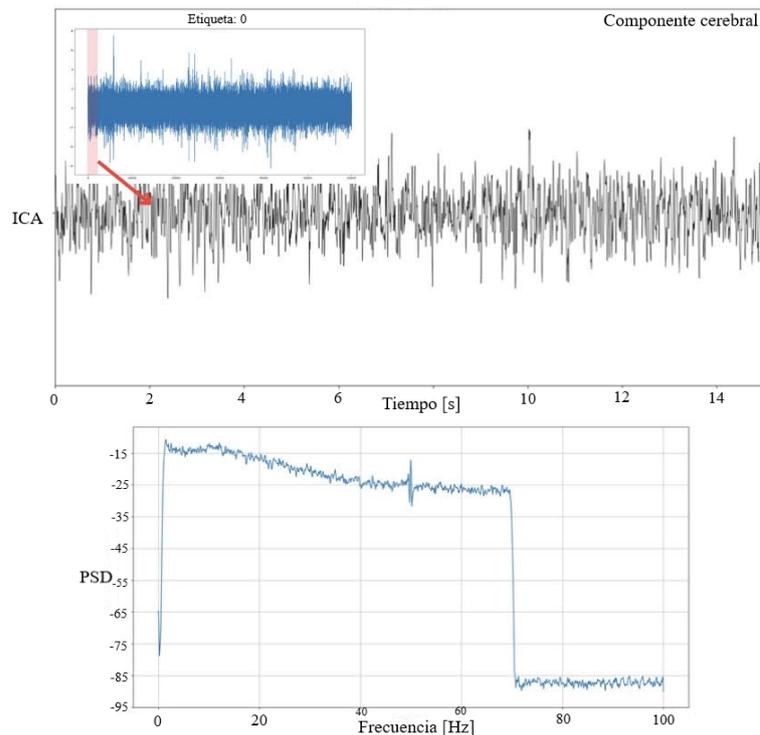
Para registrar las señales MEG se utilizó un sistema MEG Vision PQ1160C (Yokogawa Electric) con 160 canales, mediante el uso de gradiómetros axiales. La frecuencia de muestreo que se empleó fue de 1000 Hz y un filtro paso-bajo a 200 Hz. Los registros tuvieron una duración de cinco minutos por cada sujeto. En dicho tiempo los participantes se encontraban tumbados, con los ojos cerrados y en reposo. Haciendo uso de tres marcadores colocados en la cabeza de cada sujeto, se pudo tomar la referencia para determinar la posición de la cabeza; uno se situaba 5 mm por encima del nasión y los otros dos 10 mm por delante del trago en los laterales de la cabeza. Posteriormente, las señales fueron filtradas entre 1 y 70 Hz a partir de un filtro paso-banda de tipo FIR (*finite impulse response*) de orden 3000. Este filtro permitió seleccionar dichas frecuencias para limitar el ancho de banda del ruido. Además, se empleó un filtro elimina-banda a 50 Hz para eliminar el ruido proveniente de la red eléctrica (Rodríguez-González *et al.*, 2021).

Para cada sujeto y a partir de la señal MEG con 160 canales se obtuvieron 160 componentes ICA con el algoritmo *Extended Infomax ICA*. Esta metodología permite separar las señales con diferentes distribuciones espaciotemporales en sus componentes originales (Oliva-Moreno *et al.*, 2006). Dichas señales, procedentes de los distintos sensores colocados sobre la cabeza, estaban formadas por la mezcla de varias fuentes estadísticamente independientes. Aplicando ICA fue posible separar las señales en sus distintas componentes (una por canal), maximizando la información común entre las diferentes partes que componen la señal y, además, obtener la matriz de recomposición, que permite reconstruir la señal original a partir de

## 5 Materiales y Métodos

las componentes independientes (Lee *et al.*, 1999). Posteriormente, un técnico especialista etiquetó cada componente ICA según la consideraba actividad cerebral o artefacto. El etiquetado que se realizó fue el siguiente: “0” para componentes cerebrales, “1” para componentes cardíacas, “2” para componentes de red eléctrica, “3” para componentes oculares y, por último, “4” para otro tipo de componentes artefactadas. En la figura 5.1 se puede ver una componente etiquetada como cerebral, y en las figuras 5.2, 5.3 y 5.4 se pueden ver algunas de las componentes ICA etiquetadas como artefactos.

Previo a la introducción de las componentes en la herramienta diseñada, se realizó un estandarizado de estas, que consistió en restar la media de los datos y dividir entre la desviación estándar. Este es un proceso típico que permite mejorar el entrenamiento y la forma de generalizar de las CNN, al igualar el comportamiento de las señales que se comparan evitando la aparición de un cierto sesgo en los resultados obtenidos (Rodríguez-González *et al.*, 2021).



**Figura 5.1.** Componente etiquetada como cerebral. Imagen Superior: Señal de 5 minutos de duración muestreada a 1000 Hz, de la cual se ha obtenido la señal de 60000 muestras de duración. Imagen Inferior: densidad espectral de potencia de la señal (PSD, *Power Spectral Density*).

## 5 Materiales y Métodos

---

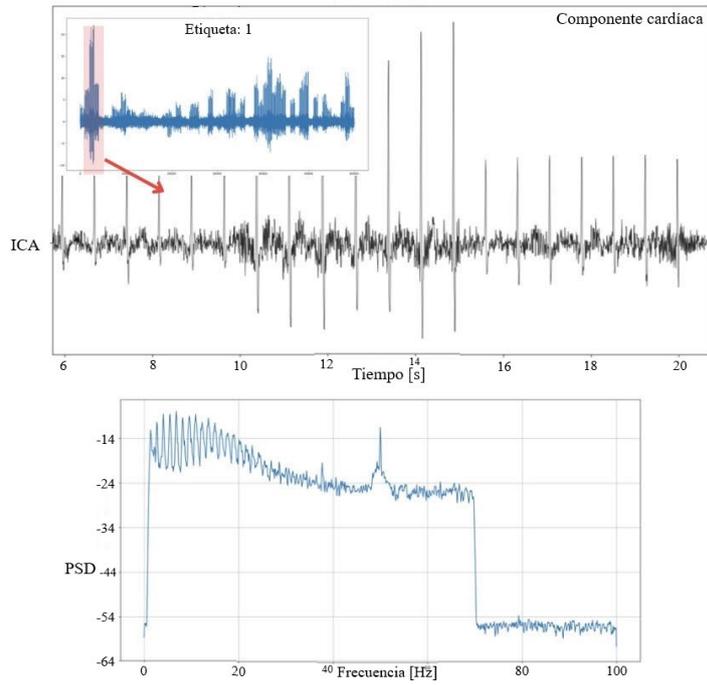


Figura 5.2. Componente etiquetada como cardíaca.

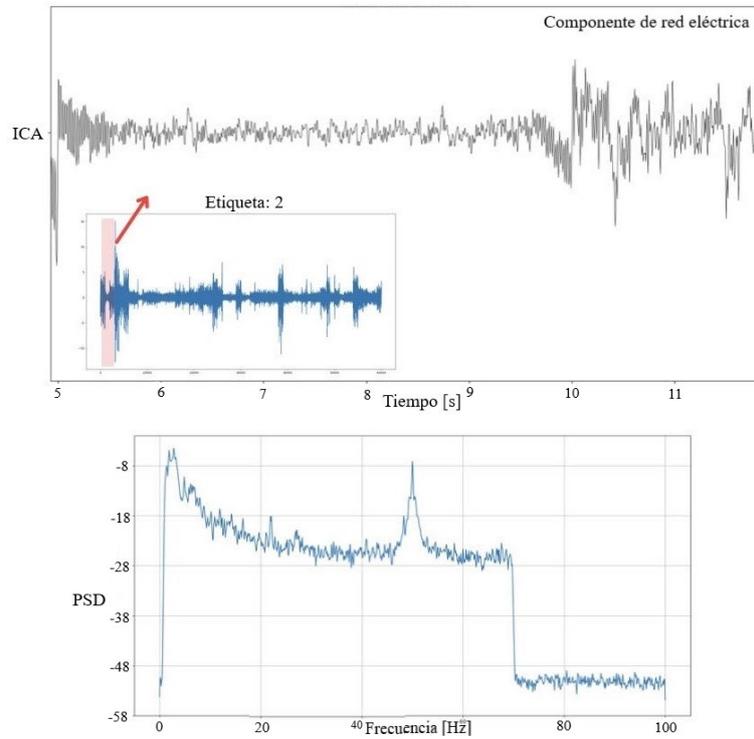


Figura 5.3. Componente etiquetada como red eléctrica.

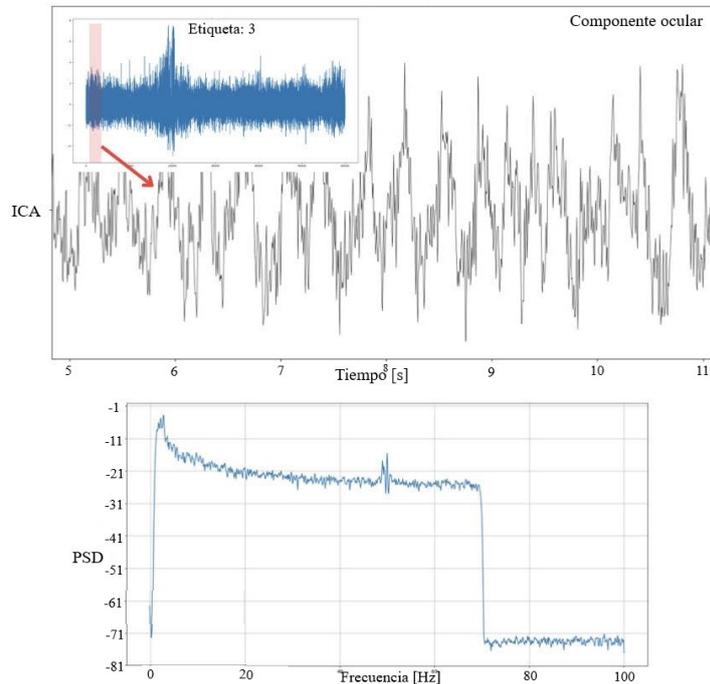


Figura 5.4. Componente etiquetada como ocular.

### 5.3. Diseño y desarrollo de un detector automático de artefactos basado en *Deep Learning*

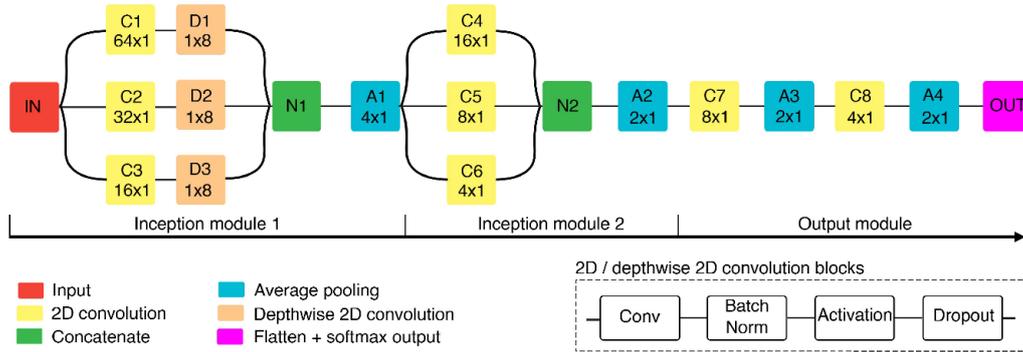
En este apartado, se va a explicar detalladamente la herramienta diseñada, desde los cambios que se han ido realizando a lo largo de su desarrollo como los hiperparámetros escogidos. Asimismo, se presentan las métricas de evaluación empleadas y los dos modelos de clasificación propuestos en este TFG.

#### 5.3.1. Configuración de la red EEG-Inception

Para construir una herramienta que permita detectar y clasificar los artefactos presentes en las señales neuronales se ha hecho uso de la CNN EEG-Inception. Esta red permite la clasificación de señales procedentes de registros de EEG y la detección de potenciales relacionados a eventos (ERP, *Event-Related Potentials*). En la figura 5.5 se muestra una visión general de su arquitectura (Santamaria-Vazquez *et al.*, 2020).

En el primer bloque se aplican tres convoluciones de dos dimensiones de 64x1, 32x1 y 16x1. Dado que se emplea una frecuencia de muestreo de 128 Hz, esos tama-

## 5 Materiales y Métodos



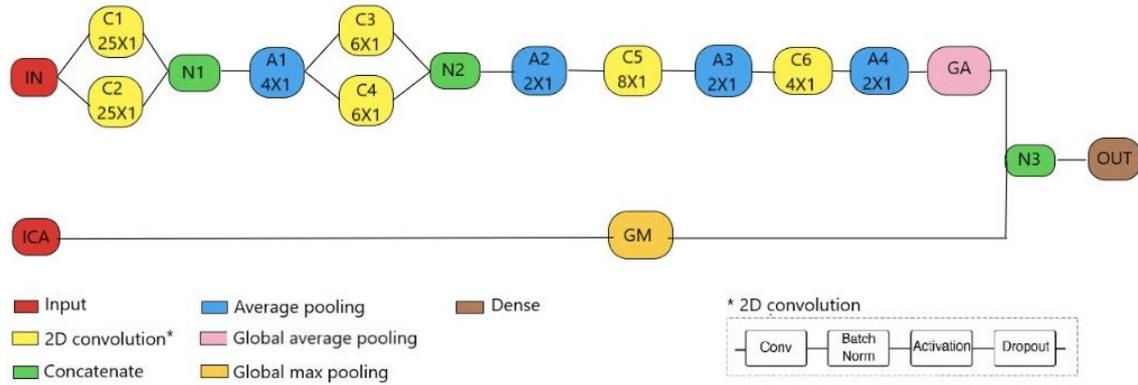
**Figura 5.5.** Arquitectura general de la red EEG-Inception (Santamaria-Vazquez *et al.*, 2020).

ños se corresponden con unas ventanas temporales de 500, 250 y 125 milisegundos, respectivamente. Estas van seguidas de tres convoluciones *depthwise*, siendo de 1x8 todas ellas, permitiendo que las señales puedan ser procesadas en el dominio espacial. Estas últimas son de tales dimensiones dado que, originalmente, esta red se pensó para registros que se realizasen con 8 electrodos EEG. A continuación, se concatenan todas las salidas ofrecidas tras la última etapa de convolución y se reducen las dimensiones aplicando un *Average-Pooling*. Seguidamente, viene el segundo bloque, que es muy similar al primero y permite extraer características temporales con un nivel de abstracción mayor al procesar de nuevo las señales transformadas tras el primer bloque. Finalmente, en el último bloque se extraen las características más significativas y complejas que se van a emplear en la clasificación final. Está compuesto por dos convoluciones 8x1 y 4x1, y dos *Average-Pooling*. La probabilidad de cada clase se estima por medio de la salida a la cual se le ha adjuntado una función de activación softmax. Cabe destacar que cada convolución está compuesta a su vez por una normalización denominada *Batch Normalization*, que permite normalizar las activaciones de salida aplicando diferentes pesos entre las neuronas y la función de activación; además, la forman una activación extra y un *Dropout*, que evitan que la red comience a memorizar, ocasionando un sobreajuste u *overfitting*.

A pesar de que esta herramienta estuviese inicialmente pensada para señales EEG, se ha decidido optar por ella, ya que, del mismo modo, permite la clasificación de componentes ICA extraídas de registros MEG. Sin embargo, se han modificado los bloques que la forman. En la figura 5.6 se observa la arquitectura resultante.

En la red EEG-Inception modificada se han introducido dos entradas, y sobre ellas se han llevado a cabo las operaciones pertinentes que han permitido obtener los resultados esperados. Una de esas entradas han sido las características extraídas

## 5 Materiales y Métodos



**Figura 5.6.** Arquitectura de la red EEG-Inception adaptada en este TFG.

de la base de datos, también denominadas *features*. Cada *feature* es una componente ICA con forma de señal de 5 minutos de duración. La otra entrada la ha formado una matriz que sirve para reconstruir una componente ICA en la señal MEG original, es decir, permite conocer qué canales registran la componente evaluada. Con la primera entrada se ha llevado a cabo el grueso de las modificaciones de la red: primeramente se ha efectuado una serie de convoluciones de diferentes dimensiones, que determinan las ventanas temporales que se estén empleando. Por ejemplo, y tal y como aparece reflejado en la figura 5.6, si se aplican dos convoluciones de tamaño 25x1, para una frecuencia de muestreo de 200 Hz, se obtendrían dos ventanas temporales de 125 milisegundos. De nuevo, dichas convoluciones están formadas a su vez por la normalización *Batch Normalization*, una activación, y el *Dropout*. A continuación, se concatenan las salidas obtenidas tras las convoluciones, y se reducen las dimensiones aplicando un *Average-Pooling*. Cabe destacar que la capa *depthwise* ha sido eliminada dado que únicamente se introduce una componente temporal cada vez, es decir, sólo se dispone de un canal de entrada, mientras que en EEG se introducen tantas componentes temporales como electrodos haya (Santamaria-Vazquez *et al.*, 2020). El siguiente bloque lo forman otras dos convoluciones, esta vez de 6x1, dado que tras el *Average-Pooling* del primer bloque las escalas se ven reducidas, permitiendo la extracción de características adicionales con un nivel de abstracción mayor. Estas convoluciones van seguidas de una concatenación y otro *Average-Pooling*. Para terminar con esta entrada, se efectúa una convolución de 8x1 y otra de 4x1, seguidas de sus *Average-Pooling* correspondientes. Finalmente, a la salida obtenida asociada a la primera entrada se le aplica un *Global Average-Pooling*, que calcula la media de los valores de una ventana de la matriz de salida. Esto se

## 5 Materiales y Métodos

---

concatena con el único bloque aplicado a la entrada ICA, un *Global Max-Pooling*, que toma el valor máximo de la matriz de recomposición, dado que permite obtener el canal más predominante asociado a cada una de las componentes ICA. Tras esto, se consigue la salida tras aplicar el bloque *Dense*.

A la hora de emplear la red EEG-Inception, se ha ido probando una serie de hiperparámetros de manera heurística. En primer lugar, se debe escoger el número de filtros temporales, permitiendo la correcta extracción de características de la señal MEG sin suponer un elevado coste computacional. Además, se ha ido variando la escala de tiempos, que determina, en milisegundos, la escala temporal de las convoluciones en cada módulo de la red; esto permite capturar diferentes patrones y características de la señal. Por otro lado, se debe elegir el valor del *Dropout rate*, es decir, en cada iteración se desactivan el porcentaje específico de neuronas que forman la red que indique dicho parámetro, evitando el *overfitting* que pueda llegar a producirse. Además, se debe elegir entre dos funciones de pérdidas para evaluar la discrepancia entre la salida predicha por el modelo y la salida real; estas son *Binary Focal Loss* y *Categorical Cross-Entropy*. La primera, útil para el caso de clasificación binaria, reduce la influencia de las clases dominantes y aumenta la importancia de las clases minoritarias mediante un parámetro denominado gamma. La segunda, empleada tanto en la clasificación binaria como en la multiclase, calcula la diferencia entre la distribución de probabilidad de las etiquetas reales y la distribución de probabilidad predicha por el modelo para cada una de las clases, buscando minimizar la distancia entre dichas distribuciones de probabilidad (O’Shea y Nash, 2015). También es posible activar o desactivar la entrada correspondiente a la matriz de recomposición, según se desee incluir la información correspondiente a cada componente ICA con respecto a los canales de los que procede. Por último, incluir los pesos de cada clase puede influir en el desbalanceo durante el entrenamiento de la red, permitiendo un mayor equilibrio en la clasificación, dado que la base de datos se encuentra sesgada hacia la clase mayoritaria.

### 5.3.2. Métricas de evaluación

En primer lugar, se ha dividido el conjunto de datos en dos grupos, que formarán el conjunto de entrenamiento y el de prueba, respectivamente. El primero será el encargado de entrenar el modelo para que aprenda a realizar la tarea específica para la que se está entrenando, en este caso, detectar y clasificar artefactos. El segundo se utilizará para medir la capacidad del modelo de generalizar y predecir con precisión

## 5 Materiales y Métodos

suficiente en datos no vistos previamente. Para ello, se ha hecho uso del método de validación cruzada *k-fold*, que permite dividir el conjunto de datos en  $k$  partes iguales (Anguita *et al.*, 2012). En este caso, se ha escogido un valor de  $k$  igual a 5, dado que permite una adecuada generalización de los resultados obtenidos sin aumentar en exceso los costes computacionales. Es decir, se ha dividido el conjunto de datos en cinco grupos y se ha realizado el proceso de entrenamiento y validación un total de cinco veces; en cada una de las iteraciones se ha tomado uno de los grupos como conjunto de validación, y los  $k-1$  restantes, en este caso los 4 restantes, forman parte del entrenamiento de la red. Seguidamente, se ha entrenado el modelo y se ha evaluado en el conjunto de prueba para, finalmente, tras haber realizado las cinco iteraciones, evaluar la media de las métricas estimadas en dichas iteraciones. En la figura 5.7 se puede ver este proceso.

Para complementar el uso del método de validación cruzada *k-fold* se ha empleado la técnica de *earlystopping*, que evita que se produzca un sobreajuste u *overfitting* durante el entrenamiento (Dodge *et al.*, 2020). Esto se evalúa en cada conjunto de validación: si su desempeño no mejora cada vez, sino que tiende a empeorar, se detiene el entrenamiento después de un cierto tiempo indicado como uno de los



**Figura 5.7.** División del conjunto de sujetos en los conjuntos de entrenamiento y prueba haciendo uso de *k-fold*.

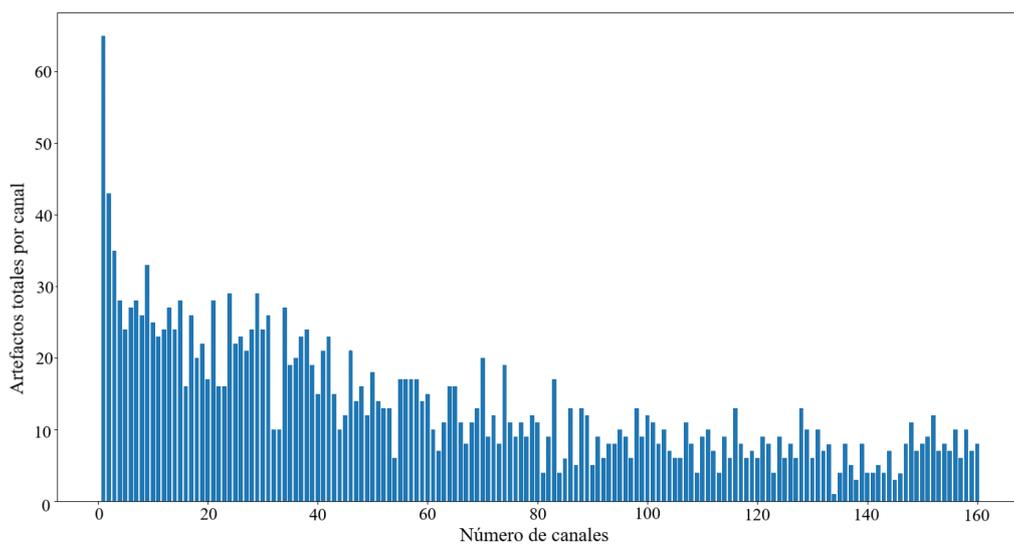
## 5 Materiales y Métodos

---

parámetros de la técnica de *earlystopping*; dicho parámetro, denominado *patience*, toma el valor de 10 épocas, para conseguir el modelo que mejor generaliza a un conjunto de datos no visto durante el entrenamiento.

Además, en las pruebas realizadas, primero se han considerado las 160 componentes (procedentes de los 160 canales); posteriormente, se ha evaluado el comportamiento de la red con sólo las 40 primeras componentes dado que, por cómo se ordenan tras aplicar ICA, estas son las que tienen mayor amplitud y, por lo tanto, más contribuyen a reconstruir la señal original. En la figura 5.8 se representan los artefactos totales en cada una de las 160 componentes. Dado que dichos artefactos se sitúan mayoritariamente en las primeras componentes, al escoger las 40 primeras se recoge la mayor parte de la variabilidad de la señal, y por tanto, de los artefactos. Además, al ser las más relevantes son las que el técnico ha tenido más cuidado de clasificar correctamente. Esto hace que sean las de mejor referencia para entrenar la CNN, permitiendo que los resultados ofrecidos sean más fáciles de interpretar y clasificar. Así, esta estrategia se ha considerado efectiva para el caso de estudio.

Por otro lado, cabe destacar que el conjunto de datos está desequilibrado: hay muchas más componentes etiquetadas como no artefactos que como artefactos, es decir, la base de datos se encuentra sesgada hacia la clase mayoritaria (en este caso, no artefactos): de 75680 componentes que hay en total (473 sujetos x 160 canales), 73539 han sido etiquetadas como no artefactos, y las 2141 restantes como artefactos. Como consecuencia, si no se ajustan adecuadamente los pesos que debe tomar cada



**Figura 5.8.** Artefactos totales en cada componente.

## 5 Materiales y Métodos

---

clase, la red tenderá a predecir erróneamente la clase mayoritaria, dado que no dispone de información suficiente sobre la minoritaria. Para solucionarlo, se ha dado diferente importancia a cada una de las clases; en concreto, se le ha dado mayor importancia a las clases minoritarias y menor a las mayoritarias. Esa importancia haría que clasificar mal todas las componentes de una clase sume el mismo valor de pérdidas que clasificar mal todas las de la otra clase. Esto es lo que se conoce como balancear o equilibrar las clases, que consigue asignar los pesos de manera inversamente proporcional a la frecuencia con la que aparecen en el conjunto de datos.

Finalmente, para determinar la calidad del proceso de clasificación, se han empleado diferentes métodos de evaluación del rendimiento; en concreto, se han calculado distintas métricas, como la sensibilidad, la especificidad, la precisión, la matriz de confusión y el coeficiente *kappa*. Estas métricas se definen a continuación (Van-Stralen *et al.*, 2009):

- Sensibilidad. Fracción de verdaderos positivos.

$$\text{Sensibilidad} = \frac{\text{verdaderos\_positivos}}{\text{verdaderos\_positivos} + \text{falsos\_negativos}} \quad (5.1)$$

- Especificidad. Fracción de verdaderos negativos.

$$\text{Especificidad} = \frac{\text{verdaderos\_negativos}}{\text{verdaderos\_negativos} + \text{falsos\_positivos}} \quad (5.2)$$

- Precisión. Exactitud en los resultados obtenidos.

$$\text{Precisión} = \frac{\text{verdaderos\_positivos} + \text{verdaderos\_negativos}}{\text{datos\_totales}} \quad (5.3)$$

- Matriz de confusión. Matriz de clasificación en la que las filas representan el etiquetado correcto, y las columnas el predicho por la red diseñada. La diagonal principal representa las clasificaciones correctas, mientras que el resto de elementos que forman la matriz se corresponden con valores erróneos.

$$MC = \begin{pmatrix} \text{verdaderos\_positivos} & \text{falsos\_positivos} \\ \text{falsos\_negativos} & \text{verdaderos\_negativos} \end{pmatrix} \quad (5.4)$$

- Coeficiente *kappa*. Evaluación del acuerdo entre el conjunto total de observa-

ciones excluyendo las concordancias producto del azar. Varía de -1 a 1, donde -1 indica una discordancia total, 0 indica un acuerdo por azar y 1 indica un acuerdo perfecto entre las distintas observaciones.

La interpretación de las matrices de confusión para los diferentes modelos (clasificación binaria y multiclase) se puede ver en la figura 5.9.

### 5.3.3. Modelos de clasificación

Con el fin de identificar las componentes ruidosas, ajenas a las señales neuronales, se han propuesto dos modelos de clasificación de artefactos y, por lo tanto, se han conseguido resultados distintos según la aproximación que se esté evaluando:

- **Clasificación binaria.** Este modelo se enfoca en identificar la presencia de artefactos en la señal, sin especificar el tipo de componente ruidosa. Se trata de un modelo sencillo y poco costoso computacionalmente, capaz de diferenciar entre componentes correspondientes a actividad cerebral y componentes correspondientes a artefactos. Para poder llevarlo a cabo, todas aquellas componentes que estuviesen etiquetadas por un técnico especialista como componentes artefactuadas (1,2,3 o 4) se han re-etiquetado en la herramienta con la etiqueta “1” (componente artefactuada en general).
- **Clasificación multiclase.** Este modelo busca detectar la presencia de artefactos de diferentes orígenes en la señal registrada y llevar a cabo una clasificación

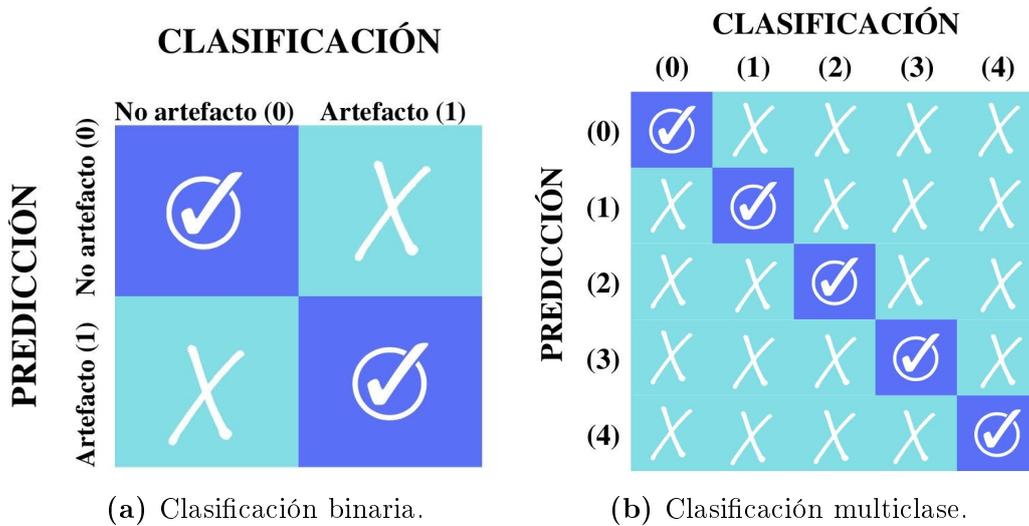


Figura 5.9. Matrices de confusión empleadas.

de estos en una categoría específica. La precisión obtenida en este caso tiende a ser menor dado que se trata de un problema más complejo, si bien la salida que ofrece puede ser de mayor utilidad para sus usuarios. Las categorías consideradas para llevar a cabo una clasificación multiclase han sido: componentes con actividad neuronal, artefactos procedentes de la actividad cardíaca, de la red eléctrica, oculares, y otro tipo de artefactos, donde se han englobado todos aquellos cuya procedencia resultaba difusa o desconocida. Esta clasificación coincide con la efectuada por el técnico especialista que etiquetó cada una de las componentes ICA durante el preprocesamiento de las señales.

### 5.3.4. Re-evaluación de las componentes

Finalmente, en el caso binario se ha llevado a cabo una re-evaluación de las componentes efectuada por la propia red. Únicamente se ha realizado tras la clasificación binaria, pues en la herramienta diseñada se prioriza la eliminación de los artefactos ante la clasificación de estos según su procedencia. Además, en la clasificación multiclase aumenta la complejidad de los datos incluidos en los conjuntos de entrenamiento y validación, lo que conlleva a que la red deba adaptarse a una variabilidad superior en las características y patrones de los artefactos.

Se trata de una re-evaluación iterativa y automática a partir de la clasificación efectuada previamente que, además, permite complementar el estudio realizado por un técnico para disminuir el número de errores y la subjetividad en las decisiones. El modo de funcionamiento es el siguiente: en primer lugar, y tras haber empleado la red para realizar una primera clasificación, se han calculado los *scores*, es decir, los valores numéricos que indican la probabilidad de que una determinada clase sea la correcta para una determinada entrada. En las primeras pruebas realizadas se han eliminado las componentes cerebrales y los artefactos etiquetados como su clase contraria con un *score* superior a 0.9, es decir, con un *score* propio menor que 0.1. Posteriormente, se han eliminado sólo las componentes cerebrales clasificadas con un *score* menor que 0.1 de no artefacto. Mediante estas dos aproximaciones se consiguen eliminar sólo aquellas componentes en las que la red tiene mucha seguridad clasificándolas como artefactos. Seguidamente, se han tomado aquellas componentes etiquetadas como no artefacto cuyo *score* para la categoría no artefacto era menor que un cierto valor, en concreto, 0.9. Dichas componentes se han denominado “dudosas”, pues se considera que, para el *score* escogido, existe cierta ambigüedad en la correcta clasificación de las componentes. Estas han sido eliminadas y se ha eva-

## 5 Materiales y Métodos

---

luado nuevamente el comportamiento de la red sin ellas y sin reentrenar en una primera instancia, y luego reentrenando la red. Este proceso se ha llevado a cabo unas cuantas veces de forma manual para observar los resultados ofrecidos por la red tras cada iteración.

Se ha considerado que el hecho de eliminar parte de las componentes pertenecientes a la clase no artefacto no debería perjudicar la capacidad de aprendizaje de la red pues, como se ha mencionado previamente, hay un desbalanceo hacia esta clase. Por otro lado, la razón por la cual se eliminan estas componentes se debe a que el técnico encargado de etiquetarlas puede equivocarse al identificar una componente como artefacto, mientras que es bastante improbable que una componente determinada artefacto no lo sea. Es decir, la idea se fundamenta en eliminar aquellas componentes no artefactuadas que puedan ser artefactos y que el técnico haya podido ignorar.

Para automatizar el proceso, se ha realizado un bucle que elimina todas aquellas componentes “dudosas” hasta el momento en que la red no mejore más la sensibilidad. En concreto, el entrenamiento se detiene cuando en dos épocas consecutivas no mejora el valor de dicha métrica, o cuando esta alcanza un valor superior al 95.00 %. Cabe destacar que se ha puesto mayor énfasis no en los resultados de la clasificación, pues estos mejoran, como es de esperar, al eliminar los ejemplos más difíciles de etiquetar, sino en cómo en el modelo final de esta re-evaluación se detectan más componentes artefactuadas que el técnico había dejado escapar.

---

# Capítulo 6

## Resultados

### Índice

---

<b>6.1. Introducción</b>	<b>62</b>
<b>6.2. Hiperparámetros escogidos</b>	<b>62</b>
<b>6.3. Resultados de la clasificación</b>	<b>64</b>
6.3.1. Clasificación binaria	64
6.3.2. Clasificación multiclase	65
<b>6.4. Re-evaluación y visualización de componentes</b>	<b>67</b>

---

### 6.1. Introducción

En este capítulo se van a presentar los resultados obtenidos tras haber aplicado una clasificación binaria y multiclase con la herramienta diseñada, de la manera indicada en el anterior capítulo, donde se comentarán los hiperparámetros escogidos y las pruebas realizadas. Posteriormente, se estudiarán los resultados definitivos y, además, se presentará un re-etiquetado de las componentes efectuado por la propia red.

### 6.2. Hiperparámetros escogidos

Tal y como se comentó en el anterior capítulo, los hiperparámetros que determinan el comportamiento de la herramienta diseñada han sido elegidos de manera heurística. Este proceso es muy costoso temporalmente, pero a partir de las pruebas sistemáticas realizadas se han podido encontrar soluciones cada vez más óptimas para el modelo de clasificación, según se mostrará a continuación y en las secciones expuestas posteriormente. Además, según se comentó en el anterior capítulo, para la clasificación binaria se han tenido en cuenta las 160 componentes en una primera evaluación. Los resultados obtenidos se muestran en la tabla 6.1. Posteriormente, se ha evaluado el comportamiento de la red con sólo las 40 primeras componentes, tal y como se ve en la tabla 6.2. Para la clasificación multiclase únicamente se han considerado las 40 primeras componentes.

En primer lugar, el número y el tamaño de las convoluciones efectuadas en la CNN EEG-Inception se ha ido variando por medio del parámetro denominado “escala de tiempos”, medido en milisegundos. Las que mejores resultados han proporcionado han sido (250,125), que hace referencia a dos convoluciones de tamaño 50x1 y 25x1 (primera fila de la tabla 6.1); (125,125), es decir, dos convoluciones de iguales dimensiones 25x1 (filas 2, 3 y 4 de las tablas 6.1 y 6.3); y (500,250,125), que se refiere a tres convoluciones de 100x1, 50x1 y 25x1, respectivamente (tabla 6.2). En todos los casos la frecuencia de muestreo ha sido de 200 Hz. Por otro lado, el número de filtros temporales escogido ha sido de 8 para todas las pruebas realizadas, ya que permite la correcta extracción de características de la señal MEG sin suponer un elevado coste computacional. Además, el *Dropout rate* que se ha elegido ha sido de 0.4, es decir, en cada iteración se desactiva el 40 % de las neuronas. Este valor se ha considerado óptimo para evitar el *overfitting* que pudiera llegar a producirse. En

## 6 Resultados

cuanto a la función de pérdidas, se ha ido escogiendo *Binary Focal Loss* o *Categorical Cross-Entropy* para las pruebas realizadas, si bien para la clasificación multiclase únicamente se ha hecho uso de la segunda función de pérdidas (tabla 6.3), dado que la primera sólo es aplicable a la clasificación binaria. También se ha ido variando el parámetro gamma de la función de pérdidas *Binary Focal Loss* (filas 1, 2, 3 y 4 de la tabla 6.2): las clases minoritarias han tomado mayor importancia a medida que este parámetro aumentaba su valor. Con un valor más alto, la especificidad y la precisión del modelo mejoraban, pero la sensibilidad y el coeficiente *kappa* tendían a ser peores. Cabe destacar que en ocasiones se ha obtenido la solución trivial cuando el parámetro gamma tomaba ciertos valores, por ejemplo 2 y 5 en la tabla 6.2; es decir, el modelo ha producido una solución poco útil y no ha podido realizar una clasificación precisa dado que no ha aprendido patrones significativos de los datos de entrada. Finalmente, la modificación de EEG-Inception con dos entradas, la componente ICA y su matriz de recomposición, es la evaluada en todos los resultados presentes. Por otro lado, tan solo en cuatro de ellas no se han balanceado las clases en la función de pérdidas, según se ve en las filas 1, 2, 3 y 4 de la tabla 6.2.

Tomando únicamente las 40 primeras componentes se ha obtenido el mejor resultado para una clasificación binaria, y es el que se muestra en la tabla 6.2. El mejor resultado obtenido mediante *Binary Focal Loss*, y sin balanceo de clases, ha sido con un valor de gamma igual a 4, tanto en la sensibilidad, como en la exactitud y el coeficiente *kappa*, tal y como se ve en la tabla 6.2. Sin embargo, al probar con la

Escala de tiempos [ms]	Función de pérdidas	Balanceo	Sensibilidad	Especificidad	Precisión	Kappa
(250, 125)	Focal-loss (gamma = 2)	SÍ	55.00 %	97.00 %	96.35 %	0.4400
(125, 125)	Focal-loss (gamma = 2)	SÍ	56.00 %	98.00 %	96.86 %	0.4875
(125, 125)	Focal-loss (gamma = 4)	SÍ	37.87 %	99.32 %	97.59 %	0.4588
(125, 125)	Categorical	SÍ	56.23 %	97.91 %	96.74 %	0.4771

**Tabla 6.1.** Parámetros y resultados tras analizar las 160 componentes en una clasificación binaria.

Escala de tiempos [ms]	Función de pérdidas	Balanceo	Sensibilidad	Especificidad	Precisión	Kappa
(500, 250, 125)	Focal-loss (gamma = 2)	NO	23.00 %	99.83 %	95.83 %	0.3512
(500, 250, 125)	Focal-loss (gamma = 3)	NO	36.81 %	99.66 %	96.39 %	0.4996
(500, 250, 125)	Focal-loss (gamma = 4)	NO	37.72 %	99.65 %	96.43 %	0.5086
(500, 250, 125)	Focal-loss (gamma = 5)	NO	15.31 %	99.91 %	95.51 %	0.2509
(500, 250, 125)	Categorical	SÍ	66.63 %	98.22 %	96.58 %	0.6516

**Tabla 6.2.** Parámetros y resultados tras analizar las 40 primeras componentes en una clasificación binaria.

## 6 Resultados

---

Escala de tiempos [ms]	Función de pérdidas	Balanceo	S1	S2	S3	S4	Especificidad	Precisión	Kappa
(125, 125)	Categorical	SÍ	65.19 %	46.42 %	72.09 %	23.93 %	89.04 %	87.38 %	0.3399

**Tabla 6.3.** Parámetros y resultados tras analizar la clasificación multiclase. S1: sensibilidad frente a la componente cardíaca; S2: sensibilidad frente a la red eléctrica; S3: sensibilidad frente a la ocular; S4: sensibilidad frente a otro tipo de componentes.

función de pérdidas *Categorical Cross-Entropy*, se ha visto que los resultados mejoraban significativamente. En cuanto a la clasificación multiclase, y para una escala de tiempos de (125, 125) milisegundos (tabla 6.3), la sensibilidad de la red frente a la componente asociada a la red eléctrica, la especificidad y la exactitud han sido mejores que la simulación realizada con una escala de tiempos de (500, 250, 125) milisegundos. Sin embargo, esta última ha mejorado el resto de resultados, por lo que se ha optado por analizarla más en detalle. En el siguiente apartado se ve reflejado este análisis, donde se comentan los resultados definitivos para cada modelo de la clasificación.

### 6.3. Resultados de la clasificación

A continuación, se van a exponer los resultados definitivos que ha sido posible obtener tras las simulaciones llevadas a cabo, tanto para la clasificación binaria como para la multiclase.

#### 6.3.1. Clasificación binaria

A continuación, se presentan los valores de sensibilidad, especificidad, precisión y coeficiente *kappa* obtenidos mediante la función de pérdidas *Categorical Cross-Entropy*, donde se ha visto que los resultados mejoraban significativamente, tal y como se ha comentado previamente. Esto puede apreciarse en la tabla 6.4.

Así, con un balanceo de clases y aplicando una escala de tiempos de (125, 125) milisegundos, los mejores resultados son los que se destacan a continuación.

Escala de tiempos [ms]	Función de pérdidas	Balanceo	Sensibilidad	Especificidad	Precisión	Kappa
(125, 125)	Categorical	SÍ	67.14 %	98.56 %	96.92 %	0.6824

**Tabla 6.4.** Parámetros y resultados finales tras analizar las 40 primeras componentes en una clasificación binaria.

## 6 Resultados

---

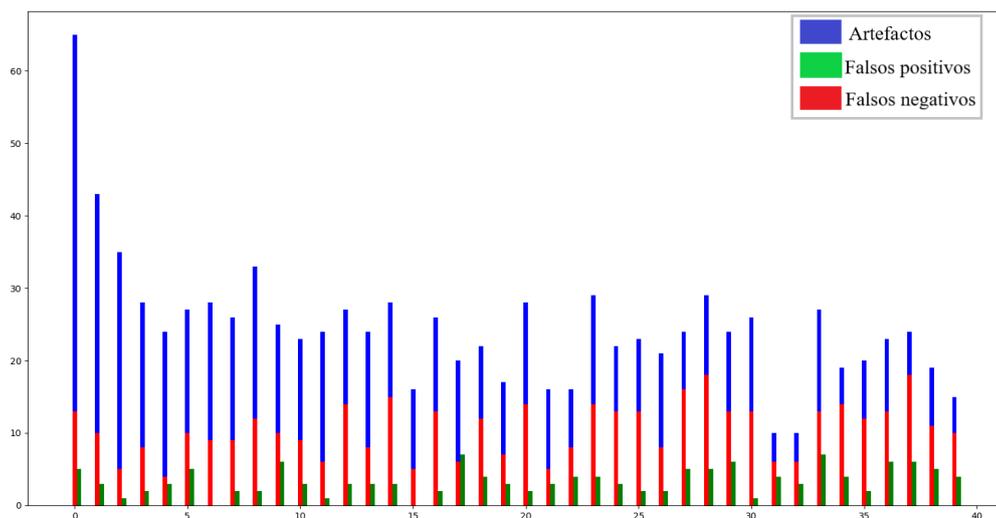
- La sensibilidad es del 67.14 %, es decir, la red ha predicho un artefacto correctamente el 67.14 % de las veces.
- La especificidad es del 98.56 %, que hace alusión a que el 98.56 % la red predijo una componente no artefactuada de forma correcta.
- La precisión lograda ha sido del 96.92 %.
- El coeficiente *kappa* es de 0.6824, es decir, un valor moderado de concordancia.

La figura 6.1 muestra la distribución de artefactos totales, falsos positivos y falsos negativos obtenidos considerando únicamente las 40 primeras componentes.

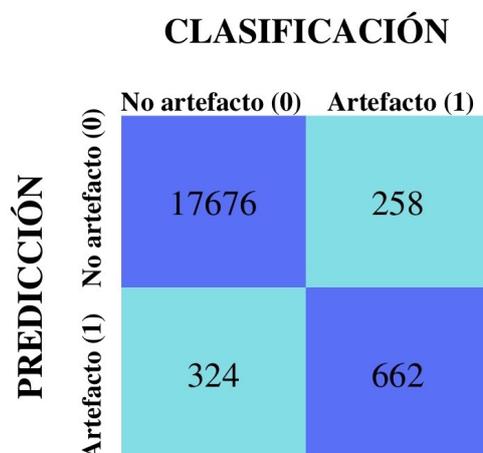
Tras evaluar estos resultados, la matriz de confusión obtenida es la que se muestra en la figura 6.2. En la red se ha introducido un total de 18920 señales, de las cuales 17934 se corresponden con componentes no artefactuadas y 986 contaminadas con artefactos. Del primer grupo, la red ha clasificado correctamente 17676 señales (especificidad del 98.56 %) y del segundo grupo ha clasificado de manera correcta 662 señales (sensibilidad de 67.14 %).

### 6.3.2. Clasificación multiclase

Los resultados definitivos para una clasificación multiclase tomando las primeras 40 componentes se muestran en la tabla 6.5, donde S1 hace referencia a la sensibilidad



**Figura 6.1.** Distribución de artefactos totales (en azul), falsos positivos (en verde) y falsos negativos (en rojo) para las 40 primeras componentes.



**Figura 6.2.** Matriz de confusión obtenida tras la clasificación binaria para las 40 primeras componentes.

de la red frente a la componente cardíaca, S2 a la de la red eléctrica, S3 a la ocular y S4 a otro tipo de componentes.

Los resultados obtenidos se detallan a continuación:

- La sensibilidad de la red frente a la componente cardíaca ha sido del 74.41 %, es decir, la red predijo un artefacto cardíaco el 74.41 % de las veces de forma correcta.
- La sensibilidad de la red ha sido del 42.85 % frente a la componente asociada a la red eléctrica.
- La sensibilidad de la red frente a la componente ocular ha sido del 81.39 %.
- La sensibilidad frente a otro tipo de componentes artefactuadas ha sido del 25.00 %.
- La especificidad es del 88.13 %, que hace alusión a que el 88.13 % la red predijo una componente no artefactuada de forma correcta.

Escala de tiempos [ms]	Función de pérdidas	Balanceo	S1	S2	S3	S4	Especificidad	Precisión	Kappa
(500, 250, 125)	Categorical	SI	74.41 %	42.85 %	81.39 %	25.00 %	88.13 %	86.90 %	0.3450

**Tabla 6.5.** Parámetros y resultados finales tras analizar la clasificación multiclase. S1: sensibilidad frente a la componente cardíaca; S2: sensibilidad frente a la red eléctrica; S3: sensibilidad frente a la ocular; S4: sensibilidad frente a otro tipo de componentes.

## 6 Resultados

- La precisión lograda ha sido del 86.90 %.
- El coeficiente *kappa* es de 0.3450.

Finalmente, la matriz de confusión obtenida tras estos últimos resultados se muestra en la figura 6.3. De nuevo, en la red se ha introducido un total de 18920 señales, de las cuales 17934 se corresponden con componentes limpias de artefactos, mientras que el resto se trata de componentes artefactuadas, donde: 727 se corresponden a artefactos cardíacos, 28 a artefactos de la red eléctrica, 43 a artefactos oculares, y 188 a otro tipo de componentes artefactuadas. De las componentes no artefactuadas, la red ha clasificado correctamente 15807 señales (especificidad del 88.13 %); de los artefactos cardíacos ha clasificado de forma correcta 541 (sensibilidad del 74.41 %), de los correspondientes a la red eléctrica 12 (sensibilidad del 42.85 %), de los oculares 35 (sensibilidad del 81.39 %), y de otro tipo de artefactos, 47 (sensibilidad del 25.00 %).

### 6.4. Re-evaluación y visualización de componentes

A continuación, se ha llevado a cabo una re-evaluación de la base de datos por la propia red a partir de las simulaciones obtenidas en las tablas 6.2 y 6.4. Para ello, primeramente se ha realizado una clasificación binaria con una escala de tiempos de (500, 250, 125) milisegundos, es decir, tres convoluciones de 100x1, 50x1 y 25x1

		CLASIFICACIÓN				
		(0)	(1)	(2)	(3)	(4)
PREDICCIÓN	(0)	15807	187	699	774	467
	(1)	87	541	47	27	25
	(2)	4	5	12	5	2
	(3)	2	2	0	35	4
	(4)	29	18	14	80	47

**Figura 6.3.** Matriz de confusión obtenida tras la clasificación multiclase para las 40 primeras componentes.

## 6 Resultados

respectivamente. Se ha optado por esta dado que ofrece una mayor resolución temporal, ofreciendo información más detallada y mejorando la capacidad de detección. Sin embargo, el mejor resultado en la clasificación binaria no se conseguía con esta escala de tiempos, lo cual se comentará más adelante. Seguidamente, se han tomado aquellas componentes, tanto cerebrales como artefactuadas, con un *score* superior a 0.9 de su clase contraria, para calcular nuevamente los parámetros de la red sin ellas y sin reentrenar. Finalmente, se ha repetido este último proceso pero reentrenando la red. Los resultados obtenidos pueden verse en la tabla 6.6.

Se puede observar que los resultados en la última iteración, es decir, sin incluir las componentes dudosas y tras reentrenar, son mucho mejores que los obtenidos tras la iteración original. Esto sucede porque, al eliminar aquellas componentes que no están produciendo resultados satisfactorios, el rendimiento general de la red neuronal tiende a mejorar.

El mismo proceso se ha llevado a cabo con una escala de tiempos de (125, 125) milisegundos, es decir, con la escala que mejores resultados ofrecía para el caso binario estudiado en un apartado anterior, y los resultados se muestran en la tabla 6.7. Como cabía esperar, los resultados son mucho mejores que tras haber aplicado una escala de tiempos de (500, 250, 125) milisegundos, al igual que sucedía en los resultados mostrados en la tabla 6.4. Para observar la progresión, destaca el aumento de sensibilidad, aún manteniendo todas las componentes artefactuadas, dado que únicamente se han eliminado las componentes cerebrales clasificadas con un *score* inferior a 0.1 de la clase no artefacto.

A mayores, se han realizado varias simulaciones tomando las 40 primeras componentes, tal y como se viene haciendo hasta ahora, pero añadiendo los artefactos de las 160 componentes totales, es decir, se han considerado todos los artefactos presentes en la base de datos. Así, la red tendrá suficiente información y variedad para clasificar los artefactos correctamente, dado que se evita el desajuste producido

Iteración	Matriz de confusión	Sensibilidad	Especificidad	Precisión	Kappa
Original	$\begin{pmatrix} 17615 & 319 \\ 329 & 657 \end{pmatrix}$	66.63 %	98.22 %	96.58 %	0.6516
Sin dudosas sin reentrenar	$\begin{pmatrix} 17332 & 185 \\ 243 & 574 \end{pmatrix}$	70.25 %	98.94 %	97.67 %	0.7162
Sin dudosas tras reentrenar	$\begin{pmatrix} 17281 & 236 \\ 228 & 589 \end{pmatrix}$	72.09 %	98.65 %	97.47 %	0.7041

**Tabla 6.6.** Matrices de confusión, sensibilidad, especificidad, precisión y coeficientes *kappa* obtenidos tras cada simulación con una escala de tiempos de (500, 250, 125).

## 6 Resultados

Iteración	Matriz de confusión	Sensibilidad	Especificidad	Precisión	Kappa
Original	$\begin{pmatrix} 17655 & 279 \\ 307 & 679 \end{pmatrix}$	68.86 %	98.44 %	96.90 %	0.6822
Sin dudosas sin reentrenar	$\begin{pmatrix} 16464 & 49 \\ 307 & 679 \end{pmatrix}$	68.86 %	99.70 %	97.97 %	0.7818
Sin dudosas tras reentrenar	$\begin{pmatrix} 16386 & 127 \\ 210 & 776 \end{pmatrix}$	78.70 %	99.23 %	98.07 %	0.8114

**Tabla 6.7.** Matrices de confusión, sensibilidad, especificidad, precisión y coeficientes *kappa* obtenidos tras cada simulación con una escala de tiempos de (125, 125).

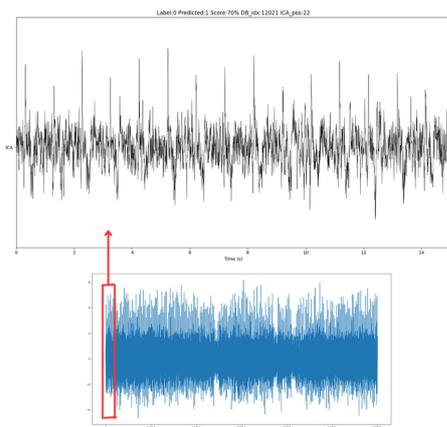
entre las componentes no artefactuadas y las contaminadas con ruido, siendo estas últimas minoritarias. Al hacer esta variación, la cantidad de artefactos está más compensada. Con esto se consigue que la red sea más precisa a la hora de detectar artefactos y no dependa tanto de las otras componentes para realizar predicciones. Para estandarizar el proceso, se ha realizado un bucle que elimina todas aquellas componentes “dudosas” hasta el momento en que la red no mejore más los resultados, es decir, se trata de un procedimiento igual que el anterior, solo que en lugar de realizar una única iteración, se realizan “N” iteraciones, siendo “N” el punto en el cual la red deja de mejorar los resultados ofrecidos. Esto puede verse en la tabla 6.8, donde se han eliminado las componentes dudosas con un *score* inferior a 0.9 sobre la anterior eliminación.

Iteración	Matriz de confusión	Sensibilidad	Especificidad	Precisión	Kappa
Original	$\begin{pmatrix} 17330 & 604 \\ 678 & 1463 \end{pmatrix}$	68.33 %	96.63 %	93.61 %	0.6596
Primera eliminación	$\begin{pmatrix} 15034 & 170 \\ 255 & 1886 \end{pmatrix}$	88.08 %	98.88 %	97.55 %	0.8848
Segunda eliminación	$\begin{pmatrix} 14455 & 20 \\ 152 & 1989 \end{pmatrix}$	92.90 %	99.86 %	98.96 %	0.9526
Tercera eliminación	$\begin{pmatrix} 13762 & 2 \\ 189 & 1952 \end{pmatrix}$	91.17 %	99.98 %	98.80 %	0.9464
Cuarta eliminación	$\begin{pmatrix} 13028 & 3 \\ 140 & 2001 \end{pmatrix}$	93.46 %	99.97 %	99.09 %	0.9602
Quinta eliminación	$\begin{pmatrix} 13027 & 0 \\ 145 & 1996 \end{pmatrix}$	93.22 %	100 %	99.04 %	0.9594
Sexta eliminación	$\begin{pmatrix} 12790 & 0 \\ 114 & 2027 \end{pmatrix}$	94.67 %	100 %	99.24 %	0.9682
Séptima iteración	$\begin{pmatrix} 12634 & 4 \\ 105 & 2036 \end{pmatrix}$	95.09 %	99.96 %	99.26 %	0.9696

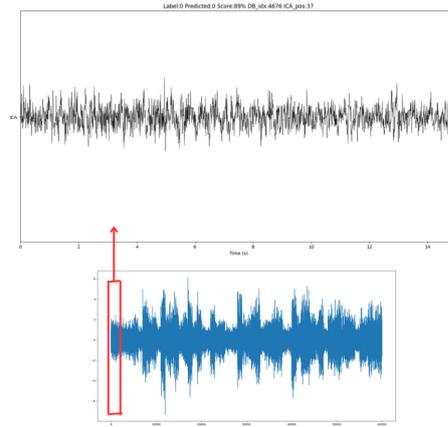
**Tabla 6.8.** Matrices de confusión, sensibilidad, especificidad, precisión y coeficientes *kappa* obtenidos tras varias simulaciones en las que se van eliminando componentes “dudosas” hasta que la red no mejore más los resultados.

## 6 Resultados

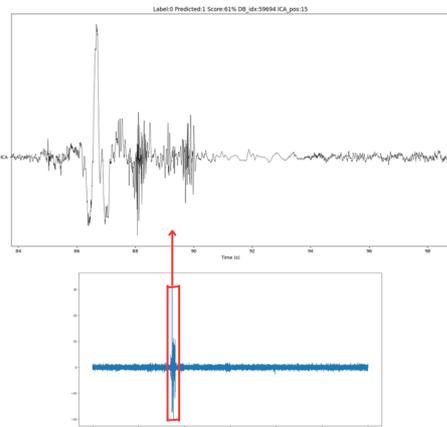
Además, en la figura 6.4 se pueden ver algunas de las componentes eliminadas, tanto aquellas que han sido bien clasificadas como no artefacto, pero aún así han sido dudosas, como aquellas que han sido erróneamente clasificadas como artefacto cuando en realidad no lo eran. Efectivamente, se puede ver que se trata de componentes dudosas debido a irregularidades que presentan en ciertos tramos de la señal. Un re-etiquetado por parte de un técnico especialista podría solventar la duda.



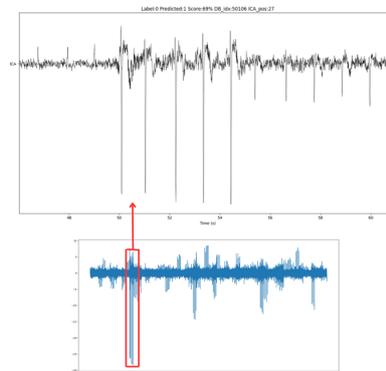
(a) Componente eliminada 1.



(b) Componente eliminada 2.



(c) Componente eliminada 3.



(d) Componente eliminada 4.

**Figura 6.4.** Cuatro componentes etiquetadas como no artefacto eliminadas de la base de datos por considerarse dudosas (*score* menor del 90 % en la clase no artefacto.) (a) Componente etiquetada como no artefacto (0), y la red ha predicho artefacto (1). *Score* del 30 %. (b) Componente etiquetada como no artefacto (0), y la red ha predicho no artefacto (0). *Score* del 89 %. (c) Componente etiquetada como no artefacto (0), y la red ha predicho artefacto (1). *Score* del 39 %. (d) Componente etiquetada como no artefacto (0), y la red ha predicho artefacto (1). *Score* del 31 %.

---

# Capítulo 7

## Discusión y limitaciones

### Índice

---

7.1. Introducción . . . . .	72
7.2. Discusión . . . . .	72
7.3. Limitaciones . . . . .	75

---

### 7.1. Introducción

El objetivo principal de este TFG consiste en la creación de una herramienta fiable que permita, de manera objetiva, detectar las componentes ruidosas en registros MEG, facilitando la tarea a los técnicos especialistas. En el presente capítulo se discuten los resultados obtenidos, se comparan con los estudios realizados previamente por otros investigadores y se evalúan las limitaciones encontradas durante el desarrollo de la herramienta diseñada.

### 7.2. Discusión

En este TFG se ha diseñado una herramienta basada en DL que, mediante el uso de CNN, ha permitido detectar y clasificar los artefactos provenientes de registros MEG. Los resultados obtenidos con la herramienta diseñada han demostrado que la clasificación manual y subjetiva realizada por los técnicos especialistas inducía a error en un número notable de ocasiones. Se ha observado que varias señales que originalmente estaban etiquetadas como componentes no artefactuadas en realidad sí que contenían partes ruidosas, y viceversa, es decir, señales etiquetadas como artefactos que realmente se correspondían con componentes cerebrales. Cabe destacar que, al ser una tarea subjetiva, queda a la decisión del técnico determinar si una componente que en su mayoría contiene información cerebral, pero durante unos segundos presenta ruido, es rechazada o conservada para reconstruir posteriormente el registro MEG. Por otro lado, tanto la clasificación binaria como la multiclase alcanzan sus valores óptimos cuando se considera la función de pérdidas *Categorical Cross-Entropy*. Sin embargo, la red ofrece resultados más precisos en el caso de la clasificación binaria, puesto que es una tarea más sencilla y menos costosa que la clasificación multiclase, si bien esta última permite obtener características más significativas de las componentes ruidosas que se están analizando. Además, debido al bajo número de ejemplos de alguna componente, como por ejemplo de la asociada a la red eléctrica, operar sin balanceo de clases hubiese sido imposible. Esto lleva a un compromiso entre especificidad y precisión, junto con la sensibilidad. Así, si la tarea multiclase se convirtiese en binaria, la red se confundiría en la clasificación de muchas componentes, pero no clasificándolas como componentes cerebrales sino como otro tipo de artefactos. Finalmente, llevar a cabo un modelo iterativo ha permitido seleccionar y aislar aquellas componentes que estaban originalmente mal etiqueta-

## 7 Discusión y limitaciones

---

das o en las que había un cierto grado de duda en su clasificación. Los resultados ofrecidos por la red sin estas componentes han mejorado significativamente y, dado que se trata de un reducido número de componentes, apuntan a la necesidad de combinar el estudio con la revisión por parte de un técnico especialista.

Estudios previos muestran que incluir las señales ECG o EOG puede ser beneficioso para la detección de artefactos (Breuer *et al.*, 2014). Así, basándose en un análisis previo mediante ICA y haciendo uso de redes neuronales, es posible aplicar diferentes estrategias de separación dependiendo del origen de la actividad (cerebral o no cerebral) que se esté detectando. Breuer *et al.* (2014) aplicaron dicha aproximación y sus resultados mostraron que tanto los artefactos cardíacos como los oculares eran eliminados de la señal MEG y se preservaba gran parte del contenido de actividad neuronal (Breuer *et al.*, 2014). Sin embargo, este tipo de métodos puede agregar complejidad y tiempo a la configuración de la adquisición de datos y pueden ser incómodos para algunos pacientes por la necesidad de incluir sensores adicionales.

Otros estudios dedicados a la detección de artefactos han hecho uso de *higher order statistics* junto con medidas de entropía para discriminar de forma automática los artefactos (Al-Qazzaz *et al.*, 2017). Estas métricas fueron calculadas por separado para cada época, y permitieron detectar el pico de actividad ruidosa y la aleatoriedad de los artefactos detectados en señales provenientes de registros EEG, a los que se les había aplicado previamente ICA. Posteriormente, sólo aquellas componentes que superaran un umbral determinado se marcaron como artefactos, y se organizaron en un nuevo conjunto sobre el cual se eliminaría el ruido mediante la Transformada Wavelet Discreta (DWT, *Discrete Wavelet Transform*). Finalmente, se pudo demostrar que la aplicación de ICA junto con la DWT preservaba la actividad neuronal tras haber eliminado los artefactos que la contaminaban.

La tabla 7.1 recoge los resultados obtenidos por diversos estudios en los que no se emplearon señales ECG o EOG, sino que se usaron exclusivamente señales MEG. El estudio de Duan *et al.* (2013) empleó una Máquina de Vectores de Soporte (SVM, *Support-Vector Machine*) entrenada con cinco características seleccionadas manualmente extraídas de las componentes ICA, para llevar a cabo una clasificación binaria. Gracias a ello, consiguieron la mayor especificidad de todos los estudios analizados (Duan *et al.*, 2013), a partir de únicamente 10 sujetos. Estos se encontraban en reposo con los ojos cerrados en una habitación aislada magnéticamente. Por otro lado, los estudios de Hasasneh *et al.* (2018) y Croce *et al.* (2019) aplicaron una red

## 7 Discusión y limitaciones

---

neuronal basada en DL, similar a la aplicada en el estudio de Garg *et al.* (2021). El estudio de Hasasneh *et al.* (2018) se basó en una CNN formada por diversas entradas, con un total de 48 sujetos, que permitía identificar los artefactos cardíacos y oculares en señales MEG para, posteriormente, llevar a cabo una clasificación binaria discriminando entre artefacto y no artefacto. Los datos recogidos se dividieron en dos categorías, los basados en tareas auditivas, visuales y motoras, y los basados en estado de reposo. El estudio efectuado por Croce *et al.* hizo uso de 10 sujetos que, al igual que Hasasneh *et al.* (2018), se les evaluó realizando una serie de tareas y en reposo. El preprocesado que se efectuó en las señales MEG fue ejecutado por varios expertos, y los resultados se corresponden a una clasificación binaria. Por último, Garg *et al.* llevaron a cabo dos estudios, uno en el año 2017 y otro en el año 2021. El primero se trató de una CNN 1D que aplicó a 49 sujetos que se encontraban en estado de reposo con los ojos cerrados, y el etiquetado previo lo realizó un único experto mediante una inspección visual. Los resultados mejoraron notablemente tras el segundo estudio realizado, donde se disponía de 217 sujetos a los que se les registraron las señales MEG tras una serie de tareas y en estado de reposo. Aquí se empleó una CNN para clasificar los artefactos en señales MEG provenientes de pestañeos, movimientos oculares, de origen cardíaco, y otro tipo de artefactos (Treacher *et al.*, 2021). El hecho de emplear únicamente las señales MEG y la alta precisión obtenida les llevó a concluir que no era necesario la identificación y clasificación de artefactos por parte de los especialistas. En último lugar, se muestra el modelo diseñado en este TFG, que supera notablemente en el número de sujetos empleados al resto de estudios analizados. Los pacientes se encontraban en un estado de reposo con los ojos cerrados, y se aplicó ICA junto con una inspección visual por parte de varios expertos. Los resultados que se han obtenido se corresponden con las dos situaciones planteadas: clasificación binaria y clasificación multiclase, discriminando, para este último caso, los artefactos de origen cardíaco, de red eléctrica, ocular y otro tipo de artefactos. Estos son comparables con los obtenidos por el resto de los autores.

La tabla 7.1 se divide en las siguientes columnas:

- Estudio: nombre del estudio realizado
  - 1: Duan *et al.* 2013.
  - 2: Hasasneh *et al.* 2018.
  - 3: Garg *et al.* 2017.
  - 4: Croce *et al.* 2019.

- 5: Garg et al. 2021.
- 6: **Modelo diseñado en este TFG.**
- Modelo: tipo de método usado en el estudio
  - SVM.
  - CNN 1 - CNN basada en DL (múltiples entradas).
  - CNN 2 - CNN (una única entrada).
  - NA - Dato no proporcionado.
- Sujetos: Número de sujetos en la muestra del estudio.
- Estado: Estado de los pacientes durante el registro.
  - A: En reposo con los ojos cerrados.
  - B: Basado en tareas y en reposo con los ojos cerrados.
- Etiquetado: Etiquetado previo.
  - i: Inspección manual.
  - ii: Técnicas de análisis independientes e inspección visual.
  - iii: Inspección visual por medio de un único experto.
  - iv: Inspección visual por medio de varios expertos.
  - v: Inspección visual independiente por medio de 4 expertos.
  - vi: **ICA e inspección visual.**

### 7.3. Limitaciones

La herramienta diseñada mediante DL para la detección de artefactos en señales MEG ha demostrado ofrecer resultados satisfactorios que pueden facilitar el diagnóstico clínico por parte de los médicos. Aún así, existen una serie de limitaciones que se deben tener en cuenta.

Una de las principales limitaciones es el número de sujetos que forman la base de datos con la que ha sido entrenada la red, lo cual afecta la validez y la generalización de los resultados obtenidos. Esto puede deberse a que MEG es una técnica bastante

## 7 Discusión y limitaciones

Estudio	Modelo	Sujetos	Estado	Etiquetado	Sensibilidad	Especificidad	Precisión
1	SVM	10	A	i	92.01 %	95.65 %	97.41 %
2	CNN 1	48	B	ii	91.80 %	97.40 %	94.40 %
3	CNN 2	49	A	iii	79.60 %	98.20 %	95.86 %
4	N/A	10	B	iv	NA	NA	95.50 %
5	CNN 1	217	B	v	96.74 %	99.34 %	98.95 %
<b>6</b>	<b>CNN 1</b>	<b>473</b>	<b>A</b>	<b>vi</b>	<b>Binario:</b> <b>67.14 %</b> <b>Tras re-</b> <b>evaluación:</b> <b>95.09 %</b> <b>M Clase:</b> <b>74.41 % (S1),</b> <b>42.85 % (S2),</b> <b>81.39 % (S3),</b> <b>25.00 % (S4)</b>	<b>Binario:</b> <b>98.56 %</b> <b>M Clase:</b> <b>88.13 %</b>	<b>Binario:</b> <b>96.92 %,</b> <b>M Clase:</b> <b>86.90 %</b>

**Tabla 7.1.** Estudios realizados para la detección de artefactos en señales neuronales.

costosa. Por otro lado, muchas personas pueden no querer someterse a este tipo de pruebas por diferentes motivos: sensación de claustrofobia, discapacidades físicas o psíquicas, ansiedad, etc. Aunque se trata de una limitación, este trabajo se ha realizado sobre una mayor cantidad de usuarios que los comparados realizados en otros estudios.

En segundo lugar, la calidad de los datos de los que se dispone juega un papel clave en el rendimiento de la red neuronal desarrollada. Como la red ha sido entrenada con componentes ya etiquetadas por medio de un único técnico especialista, si dichas etiquetas son erróneas o imprecisas, la red neuronal puede aprender de forma incorrecta y clasificar equivocadamente. Con lo cual, resulta evidente que el etiquetado debe realizarse de manera precisa y objetiva para garantizar la máxima eficacia de la red neuronal, siendo conveniente que este proceso sea realizado por más de una persona para que esta información sea más robusta.

Otra limitación importante consiste en la fuente de información con la que se ha contado para realizar este trabajo, que únicamente disponía de señales provenientes de registros MEG. Dado que la herramienta diseñada detecta diversos tipos de señales, no exclusivamente cerebrales, parece conveniente incluir otro tipo de información para complementar el estudio, como señales provenientes de EOG o de ECG. Además, el hecho de incluir más tipos de artefactos de diferentes orígenes puede contribuir a la correcta detección y clasificación de estos por parte de la red, al mostrar información más variada y particularizar cada tipo de señal.

## 7 Discusión y limitaciones

---

Además, esta herramienta de detección de artefactos debe procesar grandes volúmenes de datos donde se requieren algoritmos computacionales potentes y una gran capacidad de cálculo. En ocasiones, la eficiencia y la escalabilidad pueden verse afectadas debido a los recursos que se necesitan, y más cuando se deben obtener resultados en tiempo real. Disponer de estrategias adecuadas de optimización puede ser clave para conseguir de forma eficiente los resultados esperados. En este sentido, se puede hacer uso de ICA junto con el Análisis de Componentes Principales (PCA, *Principal Component Analysis*), que permite seleccionar los componentes principales de un conjunto de datos, mostrando la variación total de estos haciendo uso de unas pocas componentes principales (Kaya, 2019). Aquellas que contengan artefactos se pueden eliminar si no presentan correlación alguna con la señal MEG. Esto permite reducir en gran medida las dimensiones de la base de datos empleada, mejorando la calidad de la separación de las fuentes independientes al aplicar ICA. Berg y Scherg (1991) aplicaron esta aproximación a señales que contenían artefactos oculares.

Por otro lado, el desbalanceo de clases con el que se ha debido trabajar ha podido inducir un cierto sesgo en los resultados ofrecidos, así como perjudicar la precisión obtenida, favoreciendo a la clase mayoritaria y dificultando la detección de componentes pertenecientes a la clase minoritaria. Sin embargo, gracias al balanceo de clases realizado durante el entrenamiento se ha podido paliar en gran medida este efecto, si bien con un ajuste más fino los resultados hubieran sido mejores.

A mayores, se debe mencionar que debido al uso del método de validación cruzada *k-fold* no se tiene un único modelo de clasificación, sino que se tienen varios. Esto se traduce en que no se dispone de una herramienta “cerrada” de detección y clasificación de artefactos, sino de un marco global que indica el potencial de la aproximación que se propone en este TFG si se tuvieran suficientes datos. Aún así, el método *k-fold* da una visión muy robusta del funcionamiento de la herramienta.

Por último, cabe destacar que la interpretación de los resultados ofrecidos por la red y las características extraídas pueden ser, en muchas ocasiones, difíciles de entender por los usuarios que hacen uso de la herramienta. Además, debido a la falta de transparencia de la red, la confianza en los resultados obtenidos puede llegar a disminuir, lo cual puede provocar el rechazo de la aplicación de este tipo de técnicas de AI en el ámbito clínico. En este sentido, se podría hacer uso de la técnica conocida como *Explainable Artificial Intelligence* (XAI), que permite entender y confiar en los resultados ofrecidos por la red entrenada. Esto se lleva a cabo mediante la posibilidad de ofrecer a los usuarios una justificación sobre el porqué de las decisiones tomadas,

## 7 Discusión y limitaciones

---

así como mantener los altos niveles de rendimiento conseguidos tras el entrenamiento de la red (Arrieta *et al.*, 2020).

---

# Capítulo 8

## Conclusión y líneas futuras

### Índice

---

8.1. Introducción . . . . .	80
8.2. Objetivos propuestos . . . . .	80
8.3. Conclusiones y aportaciones . . . . .	81
8.4. Líneas futuras . . . . .	81

---

### 8.1. Introducción

En este capítulo se comenta el grado de cumplimiento de los objetivos propuestos en la introducción, así como las conclusiones extraídas y las aportaciones realizadas tras la ejecución de este TFG. Por último, se presenta la posible continuación de este trabajo y las aplicaciones de la herramienta diseñada.

### 8.2. Objetivos propuestos

En el primer capítulo se presentaron una serie de objetivos que se pretendían cumplir con la ejecución de este TFG, en el que se ha desarrollado una herramienta para facilitar la detección de artefactos presentes en señales neuronales. A continuación, se muestra en qué medida se han ido completando cada uno de ellos:

1. Gracias a las lecturas efectuadas sobre las señales electromagnéticas cerebrales, EEG y MEG, que han podido encontrarse en artículos de revista, libros, tesis y múltiples estudios, se han podido comprender sus propiedades y las técnicas de procesamiento más comunes aplicadas a dichas señales.
2. Mediante la consulta exhaustiva de diferentes artículos y publicaciones, se ha profundizado en el estudio de los artefactos presentes en señales neuronales, ahondando en las técnicas aplicadas que permiten mitigar sus efectos.
3. Se han realizado una serie de cursos que, junto con lecturas complementarias en libros y revistas, han permitido entender el concepto de redes neuronales, focalizando la atención en *Deep Learning* y en las distintas técnicas que se pueden aplicar para optimizar los resultados que ofrecen.
4. Se ha desarrollado una herramienta basada en técnicas de inteligencia artificial que aplicada a señales MEG ha permitido detectar y clasificar los artefactos presentes en dichas señales.
5. A partir de la herramienta diseñada, se han evaluado los dos modelos de detección y clasificación propuestos, probando con diferentes parámetros y estudiando su precisión y estabilidad. Además, se ha llevado a cabo una limpieza de la base de datos que ha conseguido mejorar el funcionamiento de la red entrenada.

## 8 Conclusión y líneas futuras

---

6. Los resultados obtenidos tras la ejecución de este TFG han sido analizados, y se han comparado con estudios previos.
7. Para finalizar, se han extraído las conclusiones más relevantes y se han expuesto las posibles limitaciones de la herramienta diseñada, así como sus líneas futuras.

### 8.3. Conclusiones y aportaciones

Las conclusiones extraídas tras haber realizado este TFG y haber analizado cada una de sus partes son las que se muestran a continuación:

1. Los artefactos presentes en las señales provenientes de registros MEG distorsionan la señal, ocasionando una degradación en la calidad de esta, dificultando su análisis.
2. El uso de CNN ha demostrado ofrecer una alta capacidad de detección y clasificación de los tipos de artefactos más comunes en señales MEG, consiguiendo disminuir el sesgo asociado al etiquetado manual de componentes ICA artefactuadas.
3. Disponer de una selección de datos de entrenamiento, con la cantidad y la calidad adecuada de estos, es clave para lograr un buen rendimiento y desempeño de la red neuronal.
4. La herramienta diseñada tiene la capacidad de identificar señales no procedentes de actividad neuronal y, continuando en esta línea de investigación y profundizando en el uso de redes neuronales, puede ser aplicada a otro tipo de señales y de tareas de reconocimiento de patrones en el ámbito clínico.

### 8.4. Líneas futuras

Tras haber analizado las limitaciones encontradas durante el desarrollo de este TFG, a continuación se exponen una serie de líneas futuras que podrían continuar su aplicabilidad.

En primer lugar, se podría aumentar la base de datos empleada para así mejorar los resultados obtenidos por la red. En este sentido, podrían incluirse datos provenientes de otras fuentes, como por ejemplo de ECG o EOG, para que, combinadas

## 8 Conclusión y líneas futuras

---

con las señales MEG, la detección de artefactos provenientes de esas otras fuentes fuera más precisa.

Además, para mejorar la calidad de los datos de los que se dispone, sería conveniente modificar el proceso de etiquetado previo. Por ejemplo, mediante la inspección visual de varios profesionales para así conseguir diversas opiniones sobre lo que es artefacto y lo que no, o reetiquetando las componentes tras un primer entrenamiento de la red.

En cuanto a las posibles aplicaciones de la herramienta diseñada, podría extenderse su uso a señales provenientes de registros EEG, dado que, originalmente, la red EEG-Inception fue pensada para tratar con este tipo de señales y el análisis sería muy similar al realizado con señales MEG.

Por otro lado, una posible continuación de este trabajo sería detectar aquel tramo de señal neuronal que está contaminado con artefacto, pero que no afecta a la componente completa sino parcialmente, y tratar de amortiguar o eliminar su efecto para poder reconstruir posteriormente la señal cerebral minimizando la pérdida de información relevante.

Finalmente, debido a la compleja interpretación de los resultados, que en muchas ocasiones puede dar lugar a confusión, sobre todo si los usuarios de la herramienta desconocen las técnicas de AI aplicadas, sería conveniente aplicar métodos de inteligencia artificial explicable (XAI, *Explainable Artificial Intelligence*). Estos permiten obtener una mayor comprensión sobre el proceso de detección y clasificación, aumentando la transparencia de la red y la confianza por parte de los usuarios en este tipo de sistemas (Linardatos *et al.*, 2020).

## Bibliografía

- Iclabel Tutorial: EEG Independent Component Labeling. 2023. URL <https://labeling.ucsd.edu/tutorial/labels>. Accedido el 14-04-2023.
- Ahlfors, S. P., Han, J., Belliveau, J. W., y Hämäläinen, M. S. Sensitivity of MEG and EEG to source orientation. *Brain topography*, 23:227–232, 2010.
- Al-Qazzaz, N. K., Hamid Bin Mohd Ali, S., Ahmad, S. A., Islam, M. S., y Escudero, J. Automatic artifact removal in EEG of normal and demented individuals using ICA–WT during working memory tasks. *Sensors*, 17(6):1326, 2017.
- Anguita, D., Ghelardoni, L., Ghio, A., Oneto, L., y Ridella, S. The K in K-fold Cross Validation. En *European Symposium on Artificial Neural Networks*, págs. 441–446. 2012.
- Antona-Cortés, C. *Herramientas modernas en redes neuronales: la librería Keras*. B.S. thesis, Universidad Autónoma de Madrid, 2017.
- Arrieta, A. B., Díaz-Rodríguez, N., Del-Ser, J., Bennetot, A., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., y Benjamins, R. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information fusion*, 58:82–115, 2020.
- Azzerboni, B., Carpentieri, M., La-Foresta, F., y Morabito, F. C. Neural-ICA and wavelet transform for artifacts removal in surface EMG. *2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No. 04CH37541)*, 4:3223–3228, 2004.
- Barwick, D. Hans Berger on the electroencephalogram of man. The fourteen original reports on the human electroencephalogram. *Journal of the Neurological Sciences*, 13, 1971.

- Bashashati, A., Fatourechí, M., Ward, R. K., y Birch, G. E. A survey of signal processing algorithms in brain–computer interfaces based on electrical brain signals. *Journal of Neural Engineering*, 4(2):R32, 2007.
- Berg, P. y Scherg, M. Dipole modelling of eye activity and its application to the removal of eye artefacts from the eeg and meg. *Clinical Physics and Physiological Measurement*, 12(A):49, 1991.
- Brazier, M. A. *A history of the electrical activity of the brain: The first half-century*. Macmillan, 1961.
- Breuer, L., Dammers, J., Roberts, T. P. L., y Shah, N. J. Ocular and cardiac artifact rejection for real-time analysis in MEG. *Journal of Neuroscience Methods*, 233:105–114, 2014.
- Callier, P. y Sandel, O. Introduction to artificial intelligence. *Actualites Pharmaceutiques*, 60:18–20, 2021.
- Carr, J. J. y Brown, J. M. *Introduction to biomedical equipment technology*. Prentice Hall, 2001.
- Clarke, J. *SQUID '80. Superconducting Quantum Interference Devices and their Applications*. Berlin: Walter de Gruyter, 1980.
- Cohen, A. *Biomedical signals: Origin and dynamic characteristics; frequency-domain analysis*. CRC Press, 2006.
- Cohen, D. Magnetoencephalography: evidence of magnetic fields produced by alpha-rhythm currents. *Science*, 161(3843):784–786, 1968.
- Cohen, M. X. Where does EEG come from and what does it mean? *Trends in Neurosciences*, 40:208–218, 2017.
- Croce, P., Zappasodi, F., Marzetti, L., Merla, A., Pizzella, V., y Chiarelli, A. M. Deep convolutional neural networks for feature-less automatic classification of independent components in multi-channel electrophysiological brain recordings. *IEEE Transactions on Biomedical Engineering*, 66, 2019.
- Cummings, J. L., Vinters, H. V., y Felix, J. *La neuropsiquiatría de la enfermedad de Alzheimer y demencias relacionadas*. Atlas Medical Publishing, 2004.

- Daly, I., Pichiorri, F., Faller, J., Kaiser, V., Kreilinger, A., Scherer, R., y Müller-Putz, G. What does clean EEG look like? En *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, págs. 3963–3966. 2012.
- Darcey, T., Ary, J., y Fender, D. Methods for the localization of electrical sources in the human brain. *Progress in Brain Research*, 54:128–134, 1980.
- Dodge, J., Ilharco, G., Schwartz, R., Farhadi, A., Hajishirzi, H., y Smith, N. Fine-tuning pretrained language models: Weight initializations, data orders, and early stopping. *arXiv preprint arXiv:2002.06305*, 2020.
- Duan, F., Phothisonothai, M., Kikuchi, M., Yoshimura, Y., Minabe, Y., Watanabe, K., y Aihara, K. Boosting specificity of MEG artifact removal by weighted support vector machine. En *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, págs. 6039–6042. 2013.
- Ertam, F. y Aydın, G. Data classification with deep learning using TensorFlow. En *2017 International Conference on Computer Science and Engineering (UBMK)*, págs. 755–758. 2017.
- Escalona-Vargas, D. I. Evaluación estadística de la localización de fuentes neuroeléctricas con electroencefalografía usando metaheurísticas. *Tesis (DC)–Centro de Investigación y de Estudios Avanzados del IPN*, 2014.
- Fabietti, M., Mahmud, M., Lotfi, A., Averna, A., Gugganmos, D., Nudo, R., y Chiappalone, M. Neural network-based artifact detection in local field potentials recorded from chronically implanted neural probes. En *2020 International Joint Conference on Neural Networks (IJCNN)*, págs. 1–8. 2020.
- Hämäläinen, M., Hari, R., Ilmoniemi, R. J., Knuutila, J., y Lounasmaa, O. V. Magnetoencephalography—theory, instrumentation, and applications to noninvasive studies of the working human brain. *Reviews of Modern Physics*, 65(2):413, 1993.
- Haresign, I. M., Phillips, E., Whitehorn, M., Noreika, V., Jones, E. J. H., Leong, V., y Wass, S. V. Automatic classification of ICA components from infant EEG using MARA. *Developmental Cognitive Neuroscience*, 52, 2021.

- Hari, R. Magnetoencephalography in clinical neurophysiological assesment of human cortical functions. *Electroencephalography, Basic Principles, Clinical Applications, and Related Fields*, págs. 1165–1197, 2004.
- Hari, R., Levänen, S., y Raij, T. Timing of human cortical functions during cognition: role of MEG. *Trends in Cognitive Sciences*, 4(12):455–462, 2000.
- Hasasneh, A., Kampel, N., Sripad, P., Shah, N. J., y Dammers, J. Deep learning approach for automatic classification of ocular and cardiac artifacts in MEG data. *Journal of Engineering*, 2018, 2018.
- Hornik, K. Approximation capabilities of multilayer feedforward networks. *Neural Networks*, 4(2):251–257, 1991.
- Huan, N. y Palaniappan, R. Neural network classification of autoregressive features from electroencephalogram signals for brain–computer interface design. *Journal of Neural Engineering*, 1(3):142, 2004.
- Islam, M. K., Rastegarnia, A., y Yang, Z. Methods for artifact detection and removal from scalp EEG: A review. *Neurophysiologie Clinique/Clinical Neurophysiology*, 46(4-5):287–305, 2016.
- Janiesch, C., Zschech, P., y Heinrich, K. Machine learning and deep learning. *Electronic Markets*, 31:2–5, 2021.
- Jas, M., Engemann, D. A., Bekhti, Y., Raimondo, F., y Gramfort, A. Autoreject: Automated artifact rejection for MEG and EEG data. *NeuroImage*, 159:417–429, 2017.
- Kawakatsu, M. Application of ICA to MEG noise reduction. *Fourth international symposium on independent component analysis and blind signal separation (ICA2003)*, Nara, Japan, págs. 535–41, 2003.
- Kaya, I. A brief summary of EEG artifact handling. *Brain-computer interface, in Artificial Intelligence*, (9), 2019.
- Lee, T. W., Girolami, M., y Sejnowski, T. J. Independent component analysis using an extended infomax algorithm for mixed subgaussian and supergaussian sources. *Neural Computation*, 11(2):417–441, 1999.

- Linardatos, P., Papastefanopoulos, V., y Kotsiantis, S. Explainable AI: A review of machine learning interpretability methods. *Entropy*, 23(1):18, 2020.
- Lopes da Silva, F. EEG and MEG: Relevance to neuroscience. *Neuron*, 80, 2013.
- Lotte, F., Congedo, M., Lécuyer, A., Lamarche, F., y Arnaldi, B. A review of classification algorithms for EEG-based brain–computer interfaces. *Journal of Neural Engineering*, 4(2), 2007.
- Maestú, C., Gómez-Utrero, E., Piñeiro, R., y Sola, R. G. Magnetoencefalografía: una nueva técnica de diagnóstico funcional en neurociencia. *Revista de Neurología*, 28(11):1077–90, 1999.
- Mahmud, M., Travalin, D., Bertoldo, A., Girardi, S., Maschietto, M., y Vassanelli, S. An automated classification method for single sweep local field potentials recorded from rat barrel cortex under mechanical whisker stimulation. *Journal of Medical and Biological Engineering*, 32(6):397–404, 2012.
- Mahmud, M. y Vassanelli, S. Processing and analysis of multichannel extracellular neuronal signals: state-of-the-art and challenges. *Frontiers in Neuroscience*, 10:248, 2016.
- Mijović, B., De Vos, M., Gligorijević, I., Taelman, J., y Van Huffel, S. Source separation from single-channel recordings by combining empirical-mode decomposition and independent component analysis. *IEEE Transactions on Biomedical Engineering*, 57(9):2188–2196, 2010.
- Oliva-Moreno, L. N., Moreno-Cadenas, J. A., Flores-Nava, L. M., y Gomez-Castaneda, F. DSP implementation of extended infomax ICA algorithm for blind source separation. En *2006 3rd International Conference on Electrical and Electronics Engineering*, págs. 1–4. 2006.
- O’Shea, K. y Nash, R. An introduction to Convolutional Neural Networks. *arXiv preprint arXiv:1511.08458*, 2015.
- Pardo, E. Qué es la ingeniería biomédica: Areandina. 2023. URL <https://www.areandina.edu.co/blogs/que-es-ingenieria-biomedica>. Accedido el 29-03-2023.

- Poza Crespo, J. *Análisis tiempo-frecuencia de la actividad magnetoencefalográfica espontánea en la enfermedad de Alzheimer*. Tesis Doctoral, Universidad de Valladolid, 2008.
- Ramos-Argüelles, F., Morales, G., Egozcue, S., Pabón, R. M., y Alonso, M. T. Técnicas básicas de electroencefalografía: principios y aplicaciones clínicas. *Anales del sistema sanitario de Navarra*, 32:69–82, 2009.
- Rampp, S. y Stefan, H. On the opposition of EEG and MEG. *Clinical Neurophysiology*, 118(8):1658–1659, 2007.
- Rodríguez-González, V., Gómez, C., Hoshi, H., Shigihara, Y., Hornero, R., y Poza, J. Exploring the interactions between neurophysiology and cognitive and behavioral changes induced by a non-pharmacological treatment: a network approach. *Frontiers in Aging Neuroscience*, 13:696174, 2021.
- Ros-García, A. Sistema de percepción de elementos viarios usando técnicas de visión por computador para aplicación en conducción autónoma. *Trabajo de Fin de Máster, Universidad Politécnica de Cartagena*, 2019.
- Sanei, S. y Chambers, J. A. *EEG signal processing*. John Wiley & Sons, 2013.
- Santamaria-Vazquez, E., Martínez-Cagigal, V., Vaquerizo-Villar, F., y Hornero, R. Eeg-inception: A novel deep convolutional neural network for assistive erp-based brain-computer interfaces. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(12):2773–2782, 2020.
- Sasaki, M., Iversen, J., y Callan, D. E. Music improvisation is characterized by increase EEG spectral power in prefrontal and perceptual motor cortical sources and can be reliably classified from non-improvisatory performance. *Frontiers in Human Neuroscience*, 13:435, 2019.
- Sepúlveda, R., Montiel-Ross, O., Díaz, G., Guetierrez, D., y Castillo, O. Classification of encephalographic signals using artificial neural networks. *Computación y Sistemas*, 19:69–88, 2015.
- Sörnmo, L. y Laguna, P. Bioelectrical signal processing in cardiac and neurological applications. *Academic Press*, 8, 2005.

- Sternickel, K. y Braginski, A. I. Biomagnetism using squids: status and perspectives. *Superconductor Science and Technology*, 19(3):S160, 2006.
- Stevens, L. A. *Exploradores del cerebro*. Barral, 1974.
- Sweeney, K. T., Ward, T. E., y McLoone, S. F. Artifact removal in physiological signals—practices and possibilities. *IEEE Transactions on Information Technology in Biomedicine*, 16(3):488–500, 2012.
- Tahir-Akhtar M., Mitsuhashi W., J. C. J. Employing spatially constrained ica and wavelet denoising, for automatic removal of artifacts from multichannel eeg data. *Signal Processing*, 92:401–416, 2012.
- Talamillo-García, T. Nociones elementales para la interpretación del EEG. *Enfermería Docente*, 94, 2011.
- Taqi, A. M., Awad, A., Al-Azzo, F., y Milanova, M. The impact of multi-optimizers and data augmentation on TensorFlow convolutional neural network performance. En *2018 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)*, págs. 140–145. 2018.
- Team, T. B. All about eeg artifacts and filtering tools. 2023. URL <https://www.bitbrain.com/blog/eeg-artifacts>. Accedido el 26-04-2023.
- Treacher, A. H., Garg, P., Davenport, E., Godwin, R., Proskovec, A., Bezerra, L. G., Murugesan, G., Wagner, B., Whitlow, C. T., y Stitzel, J. D. Megnet: automatic ICA-based artifact removal for MEG using spatiotemporal convolutional neural networks. *NeuroImage*, 241:118402, 2021.
- Urigüen, J. A. y Garcia-Zapirain, B. EEG artifact removal—state-of-the-art and guidelines. *Journal of Neural Engineering*, 12(3):031001, 2015.
- Van-Stralen, K. J., Stel, V. S., Reitsma, J. B., Dekker, F. W., Zoccali, C., y Jager, K. J. Diagnostic methods I: sensitivity, specificity, and other measures of accuracy. *Kidney International*, 75(12):1257–1263, 2009.
- Vrba, J. y Robinson, S. E. Signal processing in magnetoencephalography. *Methods*, 25(2):249–271, 2001.
- Wikswow Jr, J. P., Gevins, A., y Williamson, S. J. The future of the EEG and MEG. *Electroencephalography and Clinical Neurophysiology*, 87(1):1–9, 1993.

Zangeneh Soroush, M., Tahvilian, P., Nasirpour, M. H., Maghooli, K., Sadeghniaat-Haghighi, K., Vahid Harandi, S., Abdollahi, Z., Ghazizadeh, A., y Jafarnia-Dabanloo, N. EEG artifact removal using sub-space decomposition, nonlinear dynamics, stationary wavelet transform and machine learning algorithms. *Frontiers in Physiology*, 13:1572, 2022.

Zhang, Y., Zhang, W., Reynoso-Alcántara, V., y Silva-Pereyra, J. Magnetoencephalography: Mapping the spatiotemporal dynamics of neuronal activity. *Suma Psicológica*, 21(1):45–53, 2014.