



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Informática

Clasificación de Emociones Mediante Señales EEG y
Técnicas de Aprendizaje Automático

Trabajo Fin de Grado

Grado en Ciencia de Datos

AUTOR/A: Bolta Ballester, Juan Pablo

Tutor/a: Vivancos Rubio, Emilio Pedro

Cotutor/a: Picó Pascual, Aarón

CURSO ACADÉMICO: 2023/2024

Resum

Aquest estudi se centra en el desenvolupament d'un classificad'or d'emocions mitjançant tècniques avançades d'aprenentatge automàtic i profund, utilitzant dades d'electroencefalografia (EEG). L'objectiu principal és implementar un sistema automàtic per al processament de senyals EEG, un pas fonamental per a optimitzar la qualitat dels algoritmes de classificació. El projecte inclou una detallada revisió de l'estat de l'art, la recopilació i preprocessament de les dades, l'extracció de característiques rellevants de senyals EEG i l'entrenament i comparació de diferents models de classificació. Es va aconseguir una alta precisió en el reconeixement d'emocions utilitzant els models d'aprenentatge profund desenvolupats, i es va determinar la importància crucial d'utilitzar dades de qualitat òptima per al bon funcionament d'aquests models. La integració del sistema automàtic de preprocessament de senyals també va resultar en una millora a l'hora de classificar les emocions. Els resultats proporcionen una base sòlida per a futures investigacions en el camp de la psicologia i en el de la interacció humà-computadora

Paraules clau: EEG, aprenentatge automàtic, reconeixement d'emocions, aprenentatge profund, processament de senyals

Resumen

Este estudio se centra en el desarrollo de un clasificador de emociones mediante técnicas avanzadas de aprendizaje automático y profundo, utilizando datos de electroencefalografía (EEG). El principal objetivo es implementar un sistema automático para el procesamiento de señales EEG, un paso fundamental para optimizar la calidad de los algoritmos de clasificación. El proyecto incluye una detallada revisión del estado del arte, la recopilación y procesamiento de los datos, la extracción de características relevantes de señales EEG y el entrenamiento y comparación de diferentes modelos de clasificación. Se logró una alta precisión en el reconocimiento de emociones utilizando los modelos de aprendizaje profundo desarrollados y se determinó la crucial importancia de utilizar datos de calidad óptima para el buen funcionamiento de estos modelos. La integración del sistema automático de procesamiento de señales también resultó en una mejora a la hora de clasificar las emociones. Los resultados proporcionan una base sólida para investigaciones futuras en el campo de la psicología y en el de la interacción humano-computadora.

Palabras clave: EEG, aprendizaje automático, reconocimiento de emociones, aprendizaje profundo, procesamiento de señales

Abstract

This study focuses on the development of an emotion classifier using advanced machine learning and deep learning techniques, based on electroencephalography (EEG) data. The main objective is to implement an automated system for processing EEG signals, a fundamental step to optimize the quality of classification algorithms. The project includes a detailed review of the state of the art, data collection and preprocessing, extraction of relevant EEG signal features, and the training and comparison of different classification models. High accuracy in emotion recognition was achieved using the developed deep learning models, and the crucial importance of using high-quality data for the proper functioning of these models was determined. The integration of the automated signal preprocessing system also resulted in improved emotion classification. The results provide a solid foundation for future research in the fields of psychology and human-computer interaction.

Key words: EEG, machine learning, emotion recognition, deep learning, signal processing

Índice general

Índice general	V
Índice de figuras	VII
Índice de tablas	VIII

1	Introducción	1
1.1	Motivación	1
1.2	Objetivos	2
1.3	Estructura de la memoria	2
2	Estado del arte	5
2.1	Crítica al estado del arte	9
2.2	Propuesta	9
3	Análisis del Problema	11
3.1	Contexto Teórico	11
3.1.1	EEG	11
3.1.2	Emociones	13
3.1.3	Procesamiento de señales EEG	15
3.1.4	Extracción de características de la señal	19
3.1.5	Modelos de Clasificación	20
3.1.6	Métricas de Clasificación	21
3.2	Herramientas utilizadas	21
3.2.1	Python	22
3.2.2	Matlab. EEGLAB	22
3.2.3	Cluster VRain	22
3.3	Análisis del marco legal y ético	22
3.4	Solución propuesta	23
4	Preparación y Comprensión de los Datos	25
4.1	SEED V Dataset	25
4.2	Preprocesamiento. EEGLAB Pipeline	26
4.3	Extracción de características	35
5	Evaluación y Validación de los Modelos	37
5.1	Modelo CNN	39
5.2	Modelo LSTM	41
5.2.1	LSTM+CNN	44
5.2.2	LSTM Bidireccional	47
6	Despliegue	51
6.1	Diseño del experimento	52
6.2	Procesamiento de los datos	53
6.3	Análisis de resultados	54
6.3.1	Factores que Influyen en los Resultados	54
6.3.2	Conclusiones y Propuestas de Mejora para el Experimento	55
7	Conclusiones	57

7.1	Legado	58
7.2	Relación con los estudios cursados	58
Bibliografía		61

Apéndices

A	Código Desarrollado en el Proyecto	65
A.1	Tratamiento inicial del dataset SEED-V	65
A.2	Algoritmo de preprocesamiento	66
A.3	Extracción de características y concatenación de datos	68
A.4	Modelos LSTM+CNN y LSTM Bidireccional	72
B	Relación del TFG con los Objetivos de Desarrollo Sostenible (ODS)	77

Índice de figuras

3.1	Descripción de las bandas de frecuencia del EEG [1].	12
3.2	Anatomía del cerebro [2].	13
3.3	Distribución de 62 canales EEG con Sistema 10-20. Fuente: Elaboración Propia . .	13
3.4	Rueda de emociones según Robert Plutchik [3].	14
3.5	Modelo circunplejo de James A. Russell [4]	14
3.6	Ejemplo de artefactos comunes en señales EEG. [5].	16
4.1	Procedimiento de visualización de vídeos.	25
4.2	Segmentos de interés de cada sesión.	27
4.3	Pipeline de Procesamiento en EEGLAB	27
4.4	Ejemplo EEG crudo.	28
4.5	Representación de los 62 canales utilizados.	29
4.6	EEG previo al filtrado.	30
4.7	EEG filtrado.	30
4.8	Posibles canales defectuosos.	31
4.9	Posibles canales defectuosos.	31
4.10	Canal no defectuoso.	32
4.11	Segmentos de datos no validos.	32
4.12	Resultados del ICA 1.	33
4.13	Resultados del ICA 2.	34
4.14	Aplicación del algoritmo de procesamiento sobre una señal EEG en crudo.	35
4.15	Dimensiones de un dataset tras la extracción de features.	36
4.16	Dimensiones del dataset final.	36
5.1	Comparativa gráfica de los modelos.	38
5.2	Accuracy y loss.	40
5.3	Matriz de confusión.	41
5.4	Gráficas de precisión (accuracy) y pérdida (loss) del modelo LSTM básico du- rante el entrenamiento.	42
5.5	Gráficas de precisión (accuracy) y pérdida (loss) del modelo LSTM mejorado durante el entrenamiento.	43
5.6	Gráficas de precisión (accuracy) y pérdida (loss) del modelo LSTM+CNN du- rante el entrenamiento.	46
5.7	Matriz de confusión del modelo LSTM+CNN.	46
5.8	Gráficas de precisión (accuracy) y pérdida (loss) del modelo LSTM Bidireccional durante el entrenamiento.	48
5.9	Matriz de confusión para el modelo LSTM Bidireccional en el conjunto de vali- dación.	49
6.1	Headset Ultracortex Mark IV de 16 canales.	51
6.2	Linea temporal del experimento.	52
6.3	Realización del experimento.	52
6.4	Ejemplo de señal recogida en el experimento.	53

6.5	Misma señal tras el procesamiento.	53
6.6	Comparativa del número y localización de los canales.	56

Índice de tablas

5.1	Comparativa de precisión entre modelos y datasets.	38
5.2	Arquitectura del Modelo CNN	40
5.3	Reporte de Clasificación para el modelo CNN	41
5.4	Arquitectura del Modelo LSTM	42
5.5	Modelo LSTM con Modificaciones	43
5.6	Arquitectura del Modelo LSTM+CNN	45
5.7	Reporte de Clasificación para el modelo LSTM+CNN	45
5.8	Arquitectura del Modelo LSTM Bidireccional	47
5.9	Reporte de Clasificación para el modelo LSTM Bidireccional	48

CAPÍTULO 1

Introducción

El estudio y comprensión de las emociones humanas juega un papel fundamental en diversas disciplinas como la medicina y la psicología, donde el reconocimiento y la interpretación precisa de estados emocionales es clave para la mejora del diagnóstico con pacientes. En la era actual, marcada por avances tecnológicos significativos, el interés por las emociones ha trascendido el ámbito humano, expandiéndose hacia el campo de interacción entre humanos y máquinas. El reconocimiento de emociones se ha convertido en un área de investigación crucial dentro del campo de la inteligencia artificial.

Las emociones, entendidas como procesos complejos que sentimos en base a las experiencias, tienen un profundo impacto en nuestra manera de pensar y comportarnos. Juegan un rol crucial en la percepción, atención, aprendizaje, razonamiento, toma de decisiones y interacción social [6]. Por ejemplo, es ampliamente aceptado en la literatura científica que los estados emocionales positivos pueden reforzar nuestro sistema inmunitario y mejorar nuestra salud general, mientras que los estados negativos pueden tener efectos adversos [7].

El estudio de la actividad cerebral a través de la encefalografía (EEG) destaca notablemente por su capacidad de capturar en tiempo real los patrones cambiantes del cerebro. Patrones que se pueden ver afectados por las emociones que siente el paciente, lo que convierte a la EEG en una herramienta especialmente valiosa en el contexto de la interpretación emocional.

En el ámbito tecnológico, la capacidad de las máquinas para reconocer y responder adecuadamente ante los estados emocionales humanos, constituye una de las bases del campo de la interacción humano-computadora (HMI). El reconocimiento de manera precisa de las emociones humanas puede facilitar la construcción de sistemas de interacción más inteligentes y humanizados. En este contexto, la computación afectiva [8] implica el estudio y desarrollo de sistemas capaces de procesar e interpretar las emociones humanas.

La intersección del estudio de emociones humanas, el análisis mediante EEG y el aprendizaje automático constituye un área de investigación prometedora que tiene un impacto significativo en múltiples disciplinas. El EEG, al capturar los cambios en la actividad cerebral inducidos por las emociones, proporciona una visión detallada de los procesos cerebrales. Integrar estos datos con métodos avanzados de aprendizaje automático nos permite interpretar con mayor exactitud los estados emocionales a partir de las señales eléctricas producidas por el cerebro.

1.1 Motivación

Durante gran parte de mi vida académica, mi interés se inclinó hacia el campo de la biología y la investigación. Sin embargo, debido a mi gran interés por las matemáticas y la esta-

dística, finalmente opté por estudiar Ciencia de Datos ya que era una disciplina aplicable en cualquier ámbito, incluida la biomedicina. Durante mi experiencia en el programa Erasmus, tuve la oportunidad de inscribirme al curso de Biomedical Data Science, donde pude aprender acerca de la aplicación de algoritmos en contextos médicos. Esta experiencia me permitió usar los conocimientos adquiridos sobre Ciencia de Datos en el conocimiento y mejora de la salud humana, experiencia que me motivó a enfocar mi Trabajo de Fin de Grado hacia este campo.

Inicialmente, consideré enfocar mi Trabajo de Fin de Grado en seguridad de los datos y ciberseguridad, un área directamente relacionada con mi trabajo actual. Al discutir las opciones con mi tutor, se presentó la oportunidad de trabajar con datos de encefalografía (EEG) y explorar su aplicación en la detección de emociones mediante algoritmos de clasificación. Este tema no solo se alinea con mi prolongado interés por la neurología, sino que también representa un reto para aplicar y profundizar mis conocimientos en análisis y procesamiento de datos complejos. Parte de la motivación para realizar este proyecto, proviene de la idea de contribuir tanto a la comunidad científica como a la práctica clínica, al mejorar la comprensión y capacidad para interpretar emociones en contextos médicos.

1.2 Objetivos

El principal objetivo de este Trabajo de Fin de Grado es desarrollar un clasificador de emociones utilizando técnicas avanzadas de aprendizaje automático y aprendizaje profundo, basado en datos obtenidos de electroencefalografía (EEG). Adicionalmente, se busca implementar un sistema automático para el procesamiento de señales EEG que sirva como paso previo fundamental para los algoritmos de clasificación. Los objetivos específicos planteados para alcanzar estas metas son:

1. **Revisión bibliográfica:** Realizar una revisión exhaustiva de la literatura existente sobre el reconocimiento de emociones mediante EEG y las técnicas de aprendizaje automático correspondientes.
2. **Recopilación y análisis de datos de EEG:** Obtener los datos necesarios y realizar un análisis detallado de los mismos para prepararlos para el procesamiento y la clasificación.
3. **Procesamiento de señales:** Evaluar y experimentar con diferentes técnicas de procesamiento de señales EEG, seleccionando las más eficaces para su integración en el sistema de procesamiento propuesto.
4. **Extracción de características:** Identificar y extraer las características más relevantes de las señales EEG que serán utilizadas para la clasificación de emociones.
5. **Entrenamiento y evaluación de modelos:** Comparar y evaluar diferentes modelos de clasificación para identificar el que ofrezca mejor precisión en el reconocimiento de emociones.
6. **Implementación del modelo de clasificación:** Obtener señales EEG de varios individuos nuevos para probar el modelo de clasificación desarrollado.

1.3 Estructura de la memoria

Este Trabajo de Fin de Grado está organizado en siete capítulos principales complementado con dos apéndices, destinados a facilitar la comprensión de la metodología y resultados del

estudio sobre el reconocimiento de emociones a partir de señales EEG. La memoria comienza con una introducción que establece la motivación y los objetivos del estudio, seguida de un análisis del estado del arte que contextualiza las investigaciones previas. El análisis del problema se detalla en el tercer capítulo, discutiendo desde el marco teórico del estudio, hasta los aspectos legales y éticos, para concluir con la propuesta de solución. La preparación y la comprensión de los datos se tratan en el cuarto capítulo, donde se explica la recopilación y el procesamiento de los datos EEG. Posteriormente, se evalúan los modelos de clasificación implementados y sus resultados. Para finalizar, se presenta el experimento que se ha realizado para validar estos resultados, así como las mejoras propuestas para futuras investigaciones. El documento concluye con un capítulo de conclusiones que sintetiza los hallazgos y su relevancia para los estudios cursados. Los apéndices proporcionan materiales adicionales que respaldan el análisis presentado, principalmente el código utilizado.

CAPÍTULO 2

Estado del arte

Para la realización del estado del arte sobre el reconocimiento de emociones utilizando señales EEG y técnicas de aprendizaje automático, se ha llevado a cabo la revisión sistemática de artículos científicos siguiendo la metodología PRISMA [9]. Se ha realizado en bases de datos reconocidas como *IEEE Xplore* [10] o *Web of Science (WoS)* [11]. El proceso comienza con la formulación de consultas de búsqueda que incluyen palabras clave relevantes para el tema de estudio, tales como *EEG, Emotion, Recognition, Deep Learning* y *Neural Networks*:

Una vez obtenidos los resultados preliminares, se procedió a un meticuloso proceso de selección de artículos basado en varios criterios para asegurar la obtención de la información más relevante para el proyecto.

En primer lugar, cada artículo fue inicialmente evaluado mediante la lectura de su resumen para determinar la relevancia temática con el objetivo de este trabajo. Solo se consideraron aquellos estudios que trataban explícitamente aspectos relacionados con el reconocimiento de emociones mediante EEG y tecnologías de aprendizaje automático. Se descartaron los artículos publicados hace más de 5 años para reflejar los avances más recientes en el campo, con la excepción de algún artículo anterior, debido a que siguen siendo ampliamente citados y relevantes en la literatura reciente. De los artículos recientes, se seleccionaron aquellos que habían sido revisados y citados frecuentemente en otros trabajos académicos, tratando de identificar los estudios de mayor impacto en la comunidad científica. El procedimiento de selección trata de asegurar que el siguiente estado del arte presentado en este trabajo refleja las tendencias y desarrollos más significativos en la investigación sobre el reconocimiento de emociones utilizando señales de electroencefalograma (EEG) y aprendizaje profundo.

El reconocimiento de emociones mediante EEG juega un papel relevante en diversos campos como la medicina y la psicología, con un potencial significativo para mejorar tanto el diagnóstico como el tratamiento de diversas condiciones de salud mental. La encefalografía (EEG) se ha establecido como una herramienta fundamental para medir la actividad neuronal directamente y reflejar los estados subyacentes. Se ha demostrado que un buen estado de ánimo puede optimizar las funciones fisiológicas y mejorar el sistema inmunitario, así como alterar las funciones del sistema endocrino y nervioso [7]. Las emociones tienen un impacto tanto a nivel psicológico como fisiológico, y juegan un papel adaptativo, social y motivacional en la vida humana, influyendo en la toma de decisiones, las interacciones humanas y la inteligencia [7]. Dado que las señales de electroencefalograma pueden reflejar verdaderamente el estado emocional humano, el reconocimiento de emociones basado en EEG con aprendizaje automático se ha convertido en una rama importante en el campo de la inteligencia artificial, concretamente en el ámbito de la interacción humano-computadora [12]. Mientras que las señales fisiológicas son espontáneas y de incontabilidad subjetiva, el EEG es un tipo de señal que no puede ser enmascarada [7]. El uso de EEG para el reconocimiento proporciona nuevas

posibilidades para que las máquinas comprendan y respondan a los estados emocionales humanos, con el objetivo de conseguir interacciones más naturales y efectivas entre humanos y sistemas informáticos.

Históricamente, el reconocimiento de emociones se basaba en observaciones conductuales y respuestas fisiológicas directas, como la medición de la frecuencia cardíaca, la conductancia de la piel o las expresiones faciales [13]. El modelo tradicional de reconocimiento se divide en dos pasos: extracción de características y clasificación. Las características más comunes contienen elementos del dominio del tiempo: potenciales relacionados con eventos (ERP), estadísticas de la señal (potencia, media, desviación, etc.), características del dominio de la frecuencia, y del dominio tiempo-frecuencia. Con el desarrollo de la encefalografía, se comienza a investigar la correlación entre los patrones de actividad cerebral con estados emocionales específicos. Las primeras investigaciones en este campo a menudo utilizaban métodos analíticos simples, como el análisis de frecuencias en bandas específicas de actividad cerebral. Algunos de los descubrimientos de estos primeros estudios son la correlación entre ciertas ondas y estados de alerta y ansiedad, las diferencias entre la actividad de los diferentes hemisferios cerebrales en función de la emoción positiva o negativa, o que la zona frontal del cerebro parece almacenar más activación emocional en comparación a otras regiones [14]. Con el desarrollo de los métodos y tecnología, las investigaciones tratan de emplear técnicas más complejas para identificar características EEG asociadas con emociones básicas como la alegría, tristeza o enfado. Esto incluye los primeros usos de algoritmos de aprendizaje automático para clasificar patrones de EEG y estudios que integran múltiples tipos de datos fisiológicos para crear modelos más completos.

La clasificación de emociones puede entenderse desde dos perspectivas principales: la categórica y la dimensional. La perspectiva categórica propone que existen emociones básicas, como la felicidad, la tristeza, la ira o el miedo, que son universales y reconocibles en diferentes culturas. Por otro lado, la perspectiva dimensional clasifica las emociones en un espacio continuo basado en dos dimensiones fundamentales: valencia, que mide si una emoción es positiva o negativa, y *arousal* o activación, que mide el nivel de activación o excitación del estado emocional. Este enfoque dimensional, propuesto inicialmente por James A. Russell, es ampliamente aceptado en el campo de la computación afectiva, ya que permite una representación más detallada y precisa de la complejidad emocional humana [15].

Los avances significativos en la tecnología de EEG han transformado notablemente tanto la interpretación como la usabilidad de los dispositivos, facilitando un análisis más preciso de la actividad cerebral. Paralelamente, el avance en las técnicas de procesamiento de señales ha jugado un papel crucial en la evolución del uso de EEG para el reconocimiento de emociones. Técnicas como la transformada de Fourier o los métodos basados en wavelets [16], han facilitado la transformación de las señales de EEG para su análisis. Al preprocesamiento con transformada de wavelet se le otorga una importancia considerable en estudios previos en este campo, ya que permite una localización precisa de eventos transitorios en el tiempo y la frecuencia, un aspecto crítico cuando se trata de señales EEG que reflejan respuestas emocionales rápidas.

El campo del reconocimiento de emociones tiene una transformación significativa con la introducción de técnicas de aprendizaje automático y profundo. La necesidad de un conocimiento profundo y especializado del dominio para extraer características de las señales se ha reducido considerablemente. Los enfoques modernos basados en aprendizaje automático y profundo pueden aprender las representaciones relevantes a partir de los datos. Los modelos de aprendizaje profundo, como las Redes Neuronales Convolucionales (CNN) y las Redes Neuronales Recurrentes de Memoria a Corto y Largo Plazo (LSTM), han demostrado ser especialmente eficaces, ya que pueden aprender automáticamente buenas representaciones de características, pueden descubrir patrones y relaciones en los datos a través del entrenamiento

con grandes cantidades de datos etiquetados. También, destaca la capacidad de estos modelos para manejar grandes volúmenes de datos y capturar relaciones no lineales. Estos modelos capturan complejidades en los datos de EEG que modelos más simples no pueden, ofreciendo una mejora considerable en la precisión de las tareas de clasificación de emociones.

Un enfoque relevante que aparece junto al desarrollo de las técnicas de aprendizaje automático es el de la representación multimodal. Este contexto de representación multimodal se refiere al proceso de integración de datos de diferentes fuentes, en este caso, la combinación de datos EEG junto a otras posibles modalidades como expresiones faciales o tonos de voz buscando mejorar la precisión y efectividad en la detección de estados emocionales.

Para comprender el estado actual de la investigación en el reconocimiento de emociones utilizando señales EEG en el campo del aprendizaje automático, se presentan y analizan brevemente en esta sección las contribuciones previas más significativas.

Xiang Li et al. [17] han realizado importantes contribuciones al campo del reconocimiento de emociones mediante el desarrollo de técnicas avanzadas de preprocesamiento y modelos híbridos de aprendizaje profundo. Su método de preprocesamiento integra las señales neurofisiológicas multicanal en marcos similares a una cuadrícula a través de transformaciones wavelet y escalogramas, que muestran la distribución de energía espectral de una señal. Esto permite integrar la información de múltiples canales de forma visual directa, facilitando el procesamiento conjunto de las señales y la extracción de relaciones internas entre distintos canales. Proponen un modelo híbrido que combina Redes Neuronales Convolucionales (CNN) y Redes Neuronales Recurrentes (RNN) para procesar la extracción de características, la correlación entre canales y la evolución a largo plazo de las señales. Las CNN destacan por su alta eficiencia computacional y robusta capacidad de generalización, superando a las redes neuronales tradicionales.

Otros modelos recientes de especial relevancia son el modelo 3DCANN [18] y 3DCNN [19]. Estos modelos realizan convoluciones en tres dimensiones para capturar de manera óptima la información temporal y espacial de los datos. En las redes 3DCNN, los mapas de características de una capa de convolución están interconectados con múltiples puntos temporales adyacentes de la capa anterior, lo que permite una profundización en la captura de información temporal. Estudios como el de Zhao Yuxuan et al [19], desarrollan un modelo de red neuronal convolucional tridimensional (3DCNN). Este modelo permite la extracción automática de características de las señales y considera simultáneamente las dimensiones espaciales (ubicación y canal donde ocurre la señal) y temporales (evolución de las señales a lo largo del tiempo) de las señales. Además, realizan un preprocesamiento que incorpora señales de referencia y una reubicación topológica de los electrodos. Las señales de referencia se utilizan para reducir el ruido y mejorar la precisión de las lecturas EEG. Con la reubicación de los electrodos se trata de organizarlos de manera que se maximice la calidad y relevancia de los datos recogidos. El modelo evalúa la clasificación binaria de dominancia (alta/baja) y valencia (positiva/negativa) y la combinación de estas. Liu et al. [18] también realizaron importantes aportes en el campo con el modelo de red neuronal convolucional tridimensional al que integran un mecanismo de atención espacio temporal (3DCANN). El mecanismo de atención en redes neuronales permite que los modelos se concentren dinámicamente en las partes más relevantes de los datos de entrada, asignando pesos a diferentes partes de los datos. Este proceso puede mejorar la precisión y la interpretabilidad. Al ponderar positivamente los canales asociados a regiones del cerebro donde las señales EEG son más indicativas de emociones y por otro lado, aquellos momentos específicos en el tiempo donde las señales EEG muestran cambios relevantes relacionados con las emociones.

Otras investigaciones recientes como la de Mao, Yanjing et al [7] investigan más en profundidad el uso de la técnica de LSTM, debido a su capacidad para retener y procesar información

relevante a lo largo del tiempo, lo cual es crucial para capturar las dinámicas temporales de las señales EEG. Se trata de incluir un mecanismo de olvido que permita al modelo descartar la información irrelevante anterior, para procesar nueva información de manera efectiva. Investigaron la clasificación de emociones a partir de señales EEG de corto plazo con el modelo LSTM comentado. Recolectaron 4000 muestras de EEG de cuatro emociones (neutral, felicidad, tristeza y miedo) con una duración de 3 segundos con una precisión de clasificación del 89%. También realizaron una contribución significativa con la implementación de técnicas de preprocesamiento de señales. En la investigación, se descartan ciertos canales del EEG que no son relevantes para el procesamiento de emociones, y se utilizan filtros de paso bajo y alto para eliminar el ruido de alta frecuencia y el desplazamiento de voltaje. Los datos se segmentan en fragmentos de 4 segundos y la frecuencia del muestreo original se reduce de 1000Hz a 500Hz para disminuir la cantidad de datos y mejorar la velocidad de cálculo, pero no se pierde información relevante para la clasificación. La precisión con este preprocesamiento detallado era significativamente mayor que previamente.

La falta de interpretabilidad de los algoritmos de aprendizaje profundo puede dificultar su uso en sistemas de apoyo a la toma de decisiones médicas. Mayor-Torres et al [20]. propusieron un sistema basado en SincNet, una red neuronal convolucional diseñada para ser más interpretable. Este sistema aprende a identificar qué partes del espectro de las señales EEG son más informativas para el reconocimiento de emociones, facilitando así la comprensión de lo que la red ha aprendido y mejorando su aplicabilidad en el ámbito médico. En su aplicación específica, SincNet se utilizó para analizar la actividad cerebral de individuos con Trastorno del Espectro Autista durante una tarea de reconocimiento de EEG y expresiones faciales, detectando eficazmente aquellas bandas de frecuencia que suelen estar suprimidas en estos individuos. Este enfoque mejoró la interpretabilidad del modelo y mantuvo un alto rendimiento en la clasificación de emociones. Estas contribuciones proporcionan una herramienta valiosa para la investigación y el diagnóstico en el ámbito del TEA, estableciendo un precedente para el desarrollo de modelos de aprendizaje profundo más transparentes y comprensibles en el campo de la neurociencia afectiva.

Finalmente, entre los estudios más recientes destaca el de Hoda Shrra et al. [6] quienes crearon un nuevo conjunto de datos de señales EEG recogidas de 10 participantes mientras visualizaban videos diseñados para inducir cinco emociones distintas, entre ellas, algunas no tan estudiadas previamente como el estrés, la relajación o el amor, ampliando así el alcance emocional investigado. Proporcionaron una metodología bien estructurada que cubre la selección de estímulos, el diseño experimental, las técnicas de preprocesamiento y la extracción de características, ofreciendo una guía para otros investigadores. Compararon el rendimiento de clasificadores, destacando la superioridad del modelo LSTM. Este campo ha experimentado avances significativos en los últimos años. Los desarrollos recientes en modelos de aprendizaje profundo, como las redes neuronales convolucionales y las redes neuronales recurrentes, han mejorado considerablemente la precisión en la clasificación al permitir la extracción automática de características de EEG. Otros avances comentados como la incorporación de mecanismos de atención y las mejoras en el preprocesamiento de las señales EEG, han ayudado a mejorar la precisión e interpretabilidad, así como la calidad de los datos recogidos. No solo se ha aumentado la eficacia en la detección de estados emocionales, sino que también se ha ampliado el alcance de las aplicaciones prácticas en áreas como la salud mental, la interacción humano-computadora y la tecnología de interfaces cerebrales.

Este estado del arte trata de proporcionar una visión general de los desarrollos recientes en el campo, y sirve como fundamento para mi propia investigación, que busca contribuir aún más a la comprensión y aplicación del reconocimiento de emociones mediante señales EEG, explorando nuevas técnicas y mejorando las existentes para lograr una mayor precisión y utilidad práctica.

2.1 Crítica al estado del arte

En el ámbito del reconocimiento de emociones mediante señales EEG, se han realizado numerosos estudios y desarrollos que han contribuido significativamente a la comprensión y avance de esta tecnología. Sin embargo, es fundamental analizar críticamente el estado actual del arte para identificar áreas de mejora que justifiquen este Trabajo de Fin de Grado.

Los estudios han demostrado que las técnicas de aprendizaje automático y aprendizaje profundo pueden ser utilizadas eficazmente para reconocer emociones, logrando resultados prometedores en términos de precisión y robustez de los modelos. No obstante, en esta revisión de la literatura se aprecia una falta de atención adecuada al preprocesamiento de datos EEG. Aunque se reconoce la calidad de la toma de datos y el preprocesamiento como etapas cruciales, suelen mencionarse superficialmente. Dado que las señales EEG son extremadamente ruidosas y pueden verse afectadas por movimientos de cabeza, parpadeos o electrodos mal colocados, la calidad de la toma de datos y el preprocesamiento se vuelven cruciales para obtener resultados fiables. El preprocesamiento incluye tareas esenciales como la eliminación de artefactos, el filtrado de ruido, la normalización de las señales o la segmentación adecuada de los datos. Sin un preprocesamiento adecuado los modelos pueden verse afectados por datos contaminados, lo que lleva a resultados inexactos y la disminución de la eficacia del sistema.

2.2 Propuesta

Este Trabajo de Fin de Grado trata de abarcar el ámbito del reconocimiento de emociones mediante señales EEG, desde el preprocesamiento de los datos hasta los modelos de clasificación. Los estudios revisados del estado del arte se centran en la complejidad de los modelos de clasificación y la extracción de características de las señales EEG, pero no profundizan en la importancia de un preprocesamiento riguroso de los datos EEG. Movimientos de cabeza, parpadeos o canales mal colocados producen artefactos y ruido que deterioran la calidad de las señales, y por tanto, la precisión de los modelos de clasificación.

La innovación principal de este trabajo radica en la implementación de un sistema de preprocesamiento automático y robusto que se integra con los métodos de clasificación existentes. Este sistema tiene como objetivo la mejora de la calidad de los datos antes de su uso en los algoritmos de clasificación y optimizar el proceso completo desde la adquisición de datos hasta la clasificación final de emociones. Las técnicas de filtrado, descomposición de señales y selección de canales óptimos se aplican de manera sistemática antes de la extracción de características de la señal, asegurando la limpieza de los datos.

Este enfoque trata de combinar soluciones en un flujo de trabajo que abarca desde el preprocesamiento de los datos en crudo hasta la evaluación de los modelos. La propuesta de valor consiste en mejorar la etapa de preprocesamiento de datos, lo cual es esencial para obtener resultados más precisos. Al enfocarse en las herramientas de preprocesamiento automático de las señales y su combinación con los métodos más avanzados de clasificación, se espera mejorar significativamente la precisión y eficacia de los sistemas de reconocimiento de emociones.

CAPÍTULO 3

Análisis del Problema

Este capítulo se centra en profundizar en las múltiples dimensiones del problema central de nuestro estudio: el reconocimiento de emociones a partir de señales EEG. Está estructurado en cuatro secciones principales que juntas proporcionan una base sólida para abordar el problema identificado. En primer lugar se presenta un marco teórico donde se establecen las bases conceptuales y metodológicas necesarias para el entendimiento del proyecto. Junto al marco teórico se presentan las herramientas que se han utilizado a lo largo del proyecto para tratar el problema del reconocimiento de emociones con aprendizaje automático. En la siguiente sección, se presenta la legislación y normativas éticas que rigen la recopilación y uso de datos biométricos. Finalmente, se detalla el enfoque y las metodologías adoptadas para enfrentar el problema del reconocimiento de emociones mediante EEG, explicando como se plantea tratar los problemas identificados.

3.1 Contexto Teórico

Para abordar la problemática presentada, es esencial entender los fundamentos teóricos y las herramientas que han sido utilizadas para la investigación. Este contexto teórico está dividido en varias secciones, donde cada una proporciona el conocimiento necesario para comprender la problemática. En primer lugar, se explora la teoría de la encefalografía (EEG), explicando como se generan y registran las señales eléctricas producidas en el cerebro, y por qué estas son de utilidad para el estudio de las emociones. Se discuten también los diferentes enfoques acerca de las emociones teóricas, los principales modelos y teorías que intentan explicar cómo se manifiestan y pueden medirse las emociones humanas. Posteriormente se presentan las herramientas de procesamiento de EEG utilizadas en este estudio, destacando sus capacidades y roles específicos en el análisis de datos EEG. La siguiente sección aborda los modelos de clasificación, proporcionando una visión general de las técnicas de aprendizaje automático y profundo aplicadas al reconocimiento de emociones a partir de EEG. También se tratan las herramientas de software utilizadas para implementar estos métodos.

3.1.1. EEG

La electroencefalografía (EEG) es una técnica neurofisiológica que registra la actividad eléctrica del cerebro a través de electrodos colocados en el cuero cabelludo. Esta técnica es fundamental en la neurociencia para estudiar la dinámica de la actividad cerebral y su relación con diversos estados cognitivos y emocionales.

El EEG mide las fluctuaciones del voltaje resultantes de la actividad eléctrica neuronal. Estas señales se generan principalmente por la corriente generada por las neuronas piramidales

en las capas superficiales del cerebro [21]. Las señales EEG reflejan la suma de la actividad sincrónica de millones de neuronas, ofreciendo una visión global de la actividad cerebral en tiempo real. La activación de neuronas de manera sincronizada, generará señales de alta amplitud y potencia en el registro de EEG. La amplitud del EEG tiene un rango que varía desde pocos microvoltios hasta 200 μV .

La actividad cerebral se manifiesta en diferentes patrones de ondas cerebrales, que se dividen en varias bandas de frecuencia, cada una asociada con distintos estados de actividad cerebral y funciones cognitivas:

1. **Delta (0.5-4 Hz):** Ondas de menor frecuencia y mayor amplitud en el espectro de EEG. Asociada con el sueño profundo (fase NREM) y los procesos de recuperación.
2. **Theta (4-8 Hz):** Relacionada con estados de somnolencia, relajación profunda e imaginación. Juegan un papel importante en la codificación de la memoria.
3. **Alpha (8-13 Hz):** Predominante durante estados de relajación pero en estado despierto.
4. **Beta (13-30 Hz):** Vinculada a la actividad consciente, la atención y resolución de problemas.
5. **Gamma (30-100 Hz):** Correlacionada con el procesamiento de información y la actividad cognitiva de alto nivel, como la percepción y la conciencia.

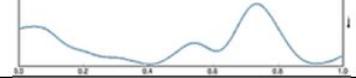
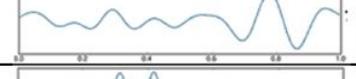
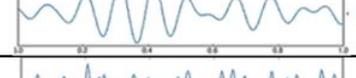
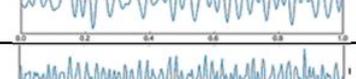
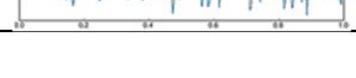
Waves	Frequency bands (Hz)	Behaviour Trait	Signal Waveform
Delta	0.3 – 4	Deep sleep	
Theta	4 – 8	Deep Meditation	
Alpha	8 – 13	Eyes closed, awake	
Beta	13 – 30	Eyes opened, thinking	
Gamma	30 and above	Unifying consciousness	

Figura 3.1: Descripción de las bandas de frecuencia del EEG [1].

Respecto a la obtención de las señales EEG, existe un estándar internacional para la colocación de los electrodos en el cuero cabelludo. Este sistema garantiza que las mediciones sean consistentes y reproducibles entre diferentes sujetos y estudios. Los electrodos se colocan en posiciones específicas con distinta distancia en función del modelo elegido, en este caso el **Sistema 10-20**, que se corresponde a las regiones anatómicas de la corteza cerebral:

- **Lóbulo Fp (Frontopolar):** Involucrado en funciones cognitivas complejas.
- **Lóbulo F (Frontal):** Responsable del razonamiento, planificación y control de movimientos.
- **Lóbulo C (Central):** Procesa la información sensorial y coordina el movimiento.
- **Lóbulo P (Parietal):** Procesa la información sensorial del tacto y la espacialidad.

- **Lóbulo O (Occipital):** Principal centro de procesamiento visual.
- **Lóbulo T (Temporal):** Involucrado en el procesamiento auditivo y la memoria.

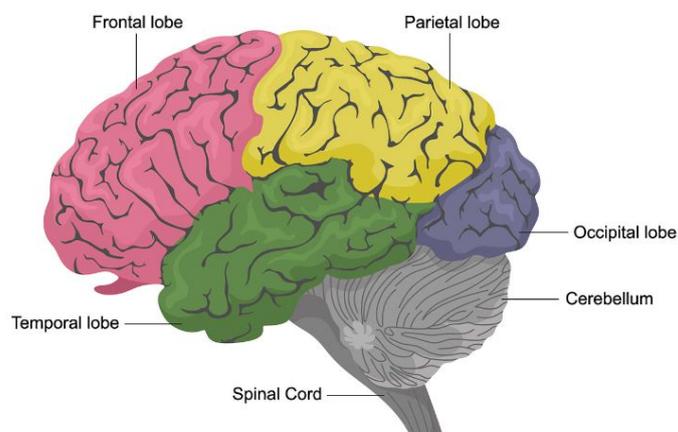


Figura 3.2: Anatomía del cerebro [2].

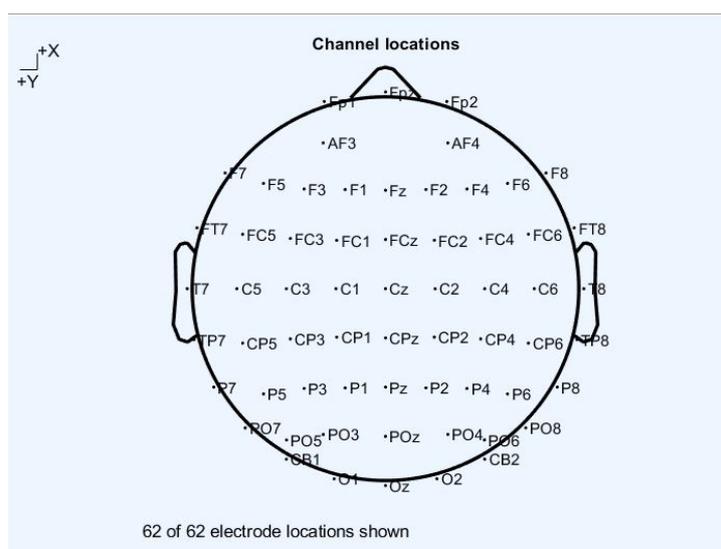


Figura 3.3: Distribución de 62 canales EEG con Sistema 10-20. Fuente: Elaboración Propia

3.1.2. Emociones

El estudio de las emociones ha sido un campo de interés en la psicología y las ciencias sociales desde hace siglos. Las emociones no solo juegan un papel crucial en la experiencia humana, sino que también influyen en la toma de decisiones, las relaciones interpersonales y la salud mental. Este marco teórico aborda las principales teorías históricas y contemporáneas sobre las emociones, destacando los enfoques evolutivos, fisiológicos y cognitivos, así como la clasificación de las emociones.

Teorías relevantes de la clasificación de emociones son la de Paul Ekman que identificó seis emociones básicas universales: felicidad, tristeza, miedo, asco, ira y sorpresa. La teoría de Robert Plutchik, centrada en la rueda de emociones que incluye ocho emociones básicas: alegría, tristeza, confianza, disgusto, miedo, ira, sorpresa y anticipación, las cuales pueden

combinarse para generar emociones más complejas [3]. James A. Russell propuso un modelo que categoriza las emociones según dos ejes: valencia (agradable a desagradable) y activación (alta a baja). Este modelo permite visualizar cómo se relacionan las diferentes emociones entre sí y cómo pueden cambiar dependiendo del contexto y la intensidad [4]. En este trabajo se ha considerado el modelo de Ekman, por su amplia aceptación en la comunidad científica del reconocimiento de emociones.

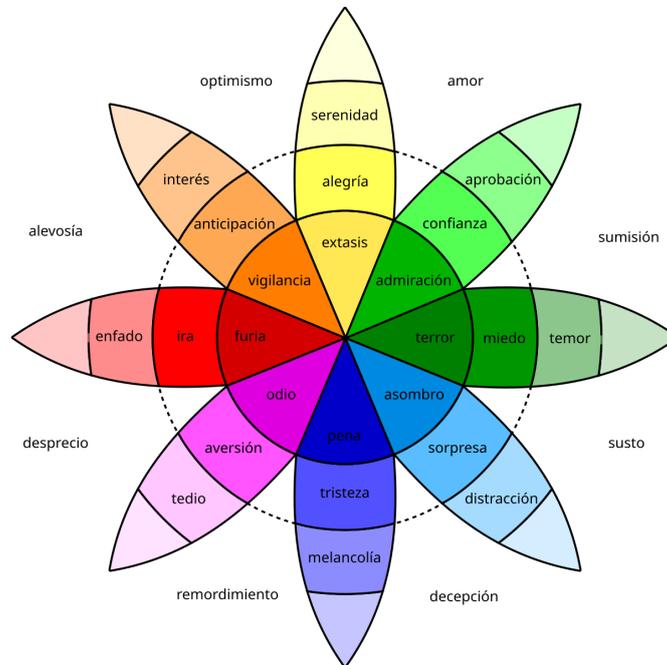


Figura 3.4: Rueda de emociones según Robert Plutchik [3].

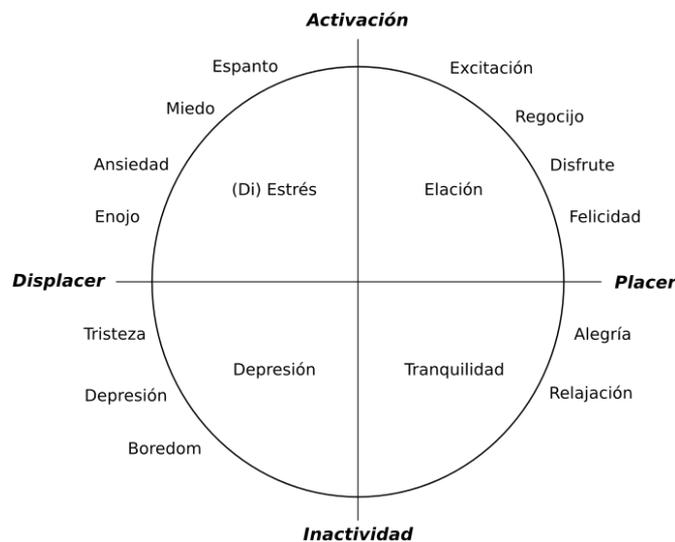


Figura 3.5: Modelo circunplejo de James A. Russell [4]

Aunque inicialmente se creía que cada emoción tenía un locus cerebral específico, investigaciones más recientes han demostrado que múltiples estructuras pueden estar implicadas en una sola emoción y que una misma estructura puede contribuir a varias emociones. Por ejemplo, la amígdala se asocia con diversas emociones negativas, incluyendo el miedo y la ira [22].

Existen diversas técnicas para detectar las emociones de un individuo, algunas relacionadas con la frecuencia cardíaca, la respiración o la conductividad de la piel. Estas técnicas permiten medir las señales fisiológicas provocadas por las emociones de manera no invasiva. En este caso de estudio se utiliza la ya comentada técnica del EEG, considerada la medida más directa y rápida de la actividad cerebral. No existe un consenso claro acerca de cuáles son o cómo se clasifican las emociones, sin embargo, que las emociones tienen su origen en el cerebro es un hecho. Debido a esto, consideramos la EEG como la herramienta más adecuada para tratar de comprender las diferentes emociones existentes, ya que esta técnica nos permite la medición más directa de la actividad eléctrica cerebral.

Como se ha podido observar, la categorización de las emociones es un tema muy complejo para el que no hay un consenso claro. La complejidad humana hace complicado definir la fina línea entre unas emociones o otras. En este estudio, nos centramos en diferenciar 5 emociones diferentes, felicidad, tristeza, miedo, asco y neutralidad.

3.1.3. Procesamiento de señales EEG

Una parte crucial del análisis de datos EEG es el procesamiento de la señal. Este tipo de señales requieren de una serie de pasos previos al análisis para garantizar el uso adecuado de los datos, ya que se trata de señales con gran cantidad de información no válida o ruidosa. A este conjunto de datos existentes en EEG pero no provenientes del cerebro y por tanto descartables, se les denomina artefactos. Es necesario comprender ciertos aspectos teóricos del procesamiento de señales para poder trabajar de manera correcta con las señales EEG obtenidas.

Características de la señal

En análisis de señales, es crucial comprender las características inherentes que definen las señales:

- **Amplitud:** Indica su nivel de intensidad. En el contexto de EEG, es de gran utilidad en la medición de la señal, donde mayores amplitudes pueden señalar una mayor actividad neuronal.
- **Frecuencia:** La frecuencia describe la velocidad a la que se repite un evento periódico en un periodo de tiempo determinado. Mide cuántos ciclos completos de onda ocurren por segundo, y se expresa en unidades de Hertz (Hz).
- **Fase:** Indica el desplazamiento relativo de una onda respecto a un tiempo de referencia.

Artefactos

Los artefactos en EEG representan señales o datos que no son originados por la actividad cerebral y pueden distorsionar la interpretación de los resultados. Entre los artefactos más comunes se encuentran los movimientos musculares y los parpadeos, que generan señales eléctricas que pueden ser recogidas por los electrodos del EEG. Los artefactos eléctricos, como la interferencia de la línea eléctrica, también son frecuentes y introducen ruido constante en la señal registrada.

Filtros de Paso Banda

Un filtro de paso banda es un tipo de filtro que permite que solo las señales dentro de un rango específico de frecuencias pasen a través de él, mientras que atenúa o elimina las señales

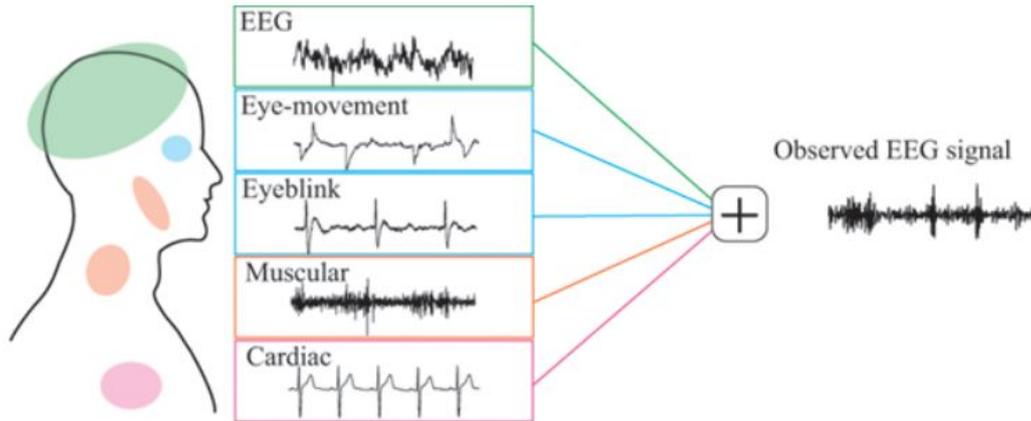


Figura 3.6: Ejemplo de artefactos comunes en señales EEG. [5].

que se encuentran por debajo o por encima de este rango. Este tipo de filtrado es comúnmente utilizado en diversas aplicaciones de procesamiento de señales donde es necesario aislar una banda de frecuencias particular y suprimir las demás.

En el contexto de las señales EEG, el filtrado de paso banda es particularmente útil porque diferentes procesos cerebrales, como las emociones, la concentración o el sueño, se manifiestan en rangos de frecuencia específicos. Al aplicar un filtro de paso banda, se puede aislar la actividad cerebral relevante en ese rango, eliminando al mismo tiempo señales no deseadas, como ruido ambiental, interferencias eléctricas u otras señales biológicas que no son de interés y que se encuentran fuera del rango filtrado. Esto asegura que el análisis se centre en las frecuencias que realmente contienen la información necesaria, mejorando la precisión y relevancia de los resultados obtenidos..

Otro tipo de filtro comúnmente utilizado es el filtro notch, un tipo de filtro utilizado para eliminar frecuencias específicas de una señal, dejando el resto de las frecuencias prácticamente intactas. En el contexto de las señales EEG, el filtro notch se aplica comúnmente para suprimir el ruido de la red eléctrica, que generalmente ocurre a 50 Hz o 60 Hz, dependiendo del país. Este ruido, conocido como interferencia de la línea de potencia, puede contaminar las señales EEG y dificultar la interpretación de los datos neurológicos. Al aplicar un filtro notch en estas frecuencias específicas, se puede mejorar significativamente la calidad de las señales EEG, permitiendo un análisis más preciso de la actividad cerebral.

Referenciado

El referenciado en EEG es un proceso esencial que se utiliza para interpretar las señales eléctricas del cerebro de manera precisa y significativa. En un estudio de EEG, los electrodos colocados en el cuero cabelludo detectan pequeñas diferencias de voltaje generadas por la actividad neuronal. Sin embargo, estas mediciones no son absolutas; en lugar de ello, cada electrodo mide la diferencia de potencial eléctrico en relación con un punto de referencia. Este punto de referencia puede ser otro electrodo, un promedio de varios electrodos, o incluso una combinación de varios puntos.

El propósito principal del referenciado es eliminar el ruido común y las interferencias que podrían afectar la calidad de la señal EEG. Al referenciar las mediciones a un punto específico, es posible reducir o eliminar componentes no deseados, como artefactos de movimiento, interferencias eléctricas externas o incluso la actividad de otras partes del cerebro que no son

relevantes para el análisis en cuestión. Asegura que las mediciones del EEG sean comoparables e interpretables.

El referenciado medio se basa en calcular la media de las señales registradas por todos los electrodos y luego restar esta media de cada señal individual. Supongamos que tenemos n electrodos, y la señal registrada por el i -ésimo electrodo se denota como $V_i(t)$, donde t representa el tiempo. El proceso se describe matemáticamente de la siguiente manera:

$$V_{\text{mean}}(t) = \frac{1}{n} \sum_{i=1}^n V_i(t) \quad (3.1)$$

Luego, para cada electrodo i , se resta esta señal media de la señal original para obtener la señal referenciada:

$$V_i^{\text{ref}}(t) = V_i(t) - V_{\text{mean}}(t) \quad (3.2)$$

Este proceso atenúa las componentes comunes a todos los electrodos, resaltando las diferencias locales en la actividad cerebral.

Eliminación de Artefactos

La eliminación de artefactos en EEG es un proceso crítico para garantizar que los datos reflejen con precisión la actividad cerebral, minimizando o eliminando las señales no deseadas que pueden distorsionar los resultados. Si no se eliminan adecuadamente, estos artefactos pueden afectar la interpretación de los datos y llevar a conclusiones incorrectas.

Aquí se presentan los 3 métodos de eliminación de artefactos utilizados en el estudio.

- **Eliminación de canales:** La eliminación automática de canales es un método utilizado para mejorar la calidad de los datos EEG al excluir canales que están significativamente contaminados por artefactos. Este proceso se puede basar en un criterio probabilístico que evalúa la desviación de las señales respecto a su distribución esperada.

Primero, se calcula la media (μ_i) y la desviación estándar (σ_i) de la señal registrada por el canal C_i a lo largo del tiempo t :

$$\mu_i = \frac{1}{N} \sum_{t=1}^N V_i(t)$$

$$\sigma_i = \sqrt{\frac{1}{N} \sum_{t=1}^N (V_i(t) - \mu_i)^2}$$

Donde $V_i(t)$ es el valor de la señal en el tiempo t y N es el número total de puntos de datos en el segmento analizado.

Luego, se calcula el valor Z para cada punto de datos en el canal C_i :

$$Z_i(t) = \frac{V_i(t) - \mu_i}{\sigma_i}$$

El valor Z indica cuántas desviaciones estándar se aleja un punto de datos de la media. Si un porcentaje significativo de los valores $Z_i(t)$ supera un umbral Z_{th} , el canal C_i se considera contaminado y debe ser eliminado:

$$\text{Eliminar } C_i \text{ si } \frac{1}{N} \sum_{t=1}^N \mathbf{1}(|Z_i(t)| > Z_{th}) > P_{th}$$

Aquí, $\mathbf{1}(\cdot)$ es la función indicadora que toma el valor 1 si la condición dentro de los paréntesis se cumple, y 0 en caso contrario. P_{th} es el porcentaje umbral que define el criterio de eliminación del canal.

- **Rechazo de segmentos continuos:** A diferencia de la eliminación de canales, que se enfoca en descartar canales enteros, este método se centra en rechazar partes específicas de la señal en todos los canales, asegurando que solo las secciones más limpias y fiables se mantengan para el análisis. Se evalúa cada segmento de la señal EEG en intervalos definidos (1 segundo por ejemplo) para determinar si excede un umbral de ruido o artefactos. Este umbral se puede definir en términos de amplitud, desviación estándar, o valores Z , y está pensado para detectar episodios en los que la señal es poco fiable, como durante movimientos bruscos, parpadeos intensos, o interferencias eléctricas.
- **ICA:** El *Análisis de Componentes Independientes (ICA)* es una técnica avanzada utilizada para la eliminación de artefactos en señales EEG. Esta técnica es particularmente eficaz porque permite descomponer la señal registrada en componentes que son estadísticamente independientes entre sí, lo que facilita la separación de la actividad cerebral de los artefactos.

El ICA se basa en la idea de que la señal EEG observada, $X(t)$, es una mezcla de múltiples fuentes independientes $S(t)$. Estas fuentes pueden incluir diferentes tipos de actividad cerebral, así como artefactos de origen no cerebral. Matemáticamente, esto se puede representar como:

$$X(t) = A \cdot S(t)$$

donde $X(t)$ es el vector de las señales observadas en todos los canales en el tiempo t , $S(t)$ es el vector de las fuentes independientes, y A es la matriz de mezcla que combina estas fuentes para formar las señales observadas.

El objetivo del ICA es encontrar una matriz de separación W tal que:

$$S(t) = W \cdot X(t)$$

W es la matriz que nos permite recuperar las fuentes independientes $S(t)$ a partir de la señal observada $X(t)$.

El ICA maximiza la independencia estadística de las fuentes $S(t)$, es decir, busca separar los componentes de manera que la ocurrencia de una fuente no proporcione información sobre la ocurrencia de otra. Este principio es clave para distinguir entre la actividad cerebral y los artefactos.

Una vez que se ha aplicado el ICA, se obtienen múltiples componentes independientes. Estos componentes pueden ser analizados individualmente para determinar si representan señales cerebrales o artefactos. Los componentes identificados como artefactos pueden ser eliminados antes de recomponer la señal limpia:

$$X_{\text{limpia}}(t) = A \cdot S_{\text{limpio}}(t)$$

donde $S_{\text{limpio}}(t)$ es el conjunto de componentes después de eliminar aquellos que corresponden a artefactos.

El ICA es altamente efectivo para separar señales cerebrales de artefactos superpuestos en la señal original, sin requerir información previa sobre el ruido. Sin embargo, su eficacia depende de la cantidad de electrodos y la correcta identificación de los componentes de artefactos, lo que puede requerir experiencia o métodos auxiliares.

3.1.4. Extracción de características de la señal

La extracción de características en señales EEG es un proceso crucial que permite transformar las señales eléctricas registradas del cerebro en un conjunto de datos más manejable y significativo para su análisis. Las señales EEG, en su forma bruta, son altamente complejas y contienen una vasta cantidad de información dispersa en el tiempo, la frecuencia y el espacio. Sin embargo, para poder interpretar estos datos y utilizarlos en aplicaciones como la clasificación de estados mentales, la detección de enfermedades neurológicas, o en interfaces cerebro-computadora, es necesario extraer características que representen de manera efectiva la actividad cerebral subyacente. Estos atributos pueden derivarse de distintos aspectos de la señal, tales como su comportamiento en el tiempo, sus componentes de frecuencia, la distribución espacial de la actividad cerebral y la complejidad no lineal de las señales.

Las características temporales son las más directas, derivadas de la forma de onda de la señal EEG en el dominio del tiempo. Ejemplos incluyen la amplitud, que mide la magnitud máxima de la señal, y la varianza, que mide la dispersión de los valores de la señal en torno a la media. Estas características son útiles para detectar eventos específicos como picos de actividad cerebral o respuestas rápidas a estímulos.

Las características de frecuencia se obtienen al analizar cómo se distribuye la energía de la señal EEG en diferentes frecuencias. Mediante técnicas como la Transformada de Fourier, se pueden identificar cuáles son las frecuencias predominantes en la señal y cómo se distribuyen a lo largo del tiempo. Esto es fundamental porque diferentes procesos cerebrales y estados mentales están asociados con distintas frecuencias. Por ejemplo, algunos estados de alerta o relajación pueden estar vinculados a frecuencias específicas, lo que permite detectar y analizar estos estados a partir de la señal EEG.

Las características espaciales sirven para analizar cómo se distribuye la actividad cerebral a través de los diferentes electrodos colocados en el cuero cabelludo. Mediante el análisis de correlaciones entre canales, es posible identificar patrones de conectividad entre diferentes regiones del cerebro o zonas que muestran mayor activación durante determinadas tareas.

Las características basadas en medidas de dinámica no lineal se centran en evaluar la imprevisibilidad o la irregularidad en la señal EEG. Un ejemplo de este tipo de características es la entropía, que proporciona una cuantificación de cómo de impredecible o desordenada es una señal. Este enfoque es especialmente valioso para explorar la dinámica cerebral bajo condiciones complejas o para identificar variaciones sutiles en el estado mental de una persona.

En este estudio se han seleccionado la Transformada de Fourier de Tiempo Corto (STFT) y la Diferencia de Entropía (DE) como métodos para la extracción de características debido a su capacidad para capturar aspectos críticos de la señal EEG. La STFT permite descomponer la señal EEG en sus componentes de frecuencia mientras conserva la información temporal, lo que es crucial para analizar cambios rápidos y transitorios en la actividad cerebral, como los que se asocian con diferentes emociones. Esta técnica facilita la identificación de patrones específicos que pueden ser indicadores de estados emocionales.

Por otro lado, la Diferencia de Entropía mide la complejidad de la señal EEG, lo que ayuda a capturar cambios sutiles en la dinámica cerebral que pueden estar relacionados con la transición entre diferentes estados emocionales. Este enfoque es particularmente efectivo para detectar variaciones en la actividad cerebral que no son fácilmente visibles a través de análisis

más simples, proporcionando una visión más profunda y detallada de cómo se manifiestan las emociones en el cerebro.

La fórmula utilizada para calcular la Diferencia de Entropía (DE) en el análisis de las señales EEG es la siguiente:

$$DE = - \int_{-\infty}^{\infty} P(x) \ln(P(x)) dx$$

Donde $P(x)$ es la función de densidad de probabilidad de la señal EEG en un segmento dado. Esta fórmula mide la complejidad y la imprevisibilidad de la señal, siendo un valor alto indicativo de mayor desorden o actividad caótica en la señal cerebral.

La elección de estos métodos está respaldada por estudios como el realizado por Liu et al. (2021), que destacan la efectividad de combinar diferentes técnicas de extracción de características para mejorar el reconocimiento de emociones mediante señales EEG [23]. En conjunto, la STFT y la Diferencia de Entropía proporcionan una representación rica y robusta de la señal cerebral, lo que las convierte en herramientas ideales para el análisis detallado y preciso en este estudio.

3.1.5. Modelos de Clasificación

La clasificación de emociones a partir de datos EEG involucra la transformación de señales cerebrales complejas en información comprensible que pueda ser utilizada para identificar diferentes estados emocionales. Este proceso requiere del uso de algoritmos de clasificación que pueden discernir los patrones en los datos que se corresponden a emociones específicas. La selección adecuada de algoritmos de clasificación es crucial debido a la variabilidad y naturaleza dinámica de las señales EEG. A continuación se explican brevemente los algoritmos de clasificación que han proporcionado mejores resultados y que se comparan en el estudio.

- **Gradient Boosting:** Es un método de ensamble que construye un modelo predictivo a partir de la combinación de varios modelos base, para crear un modelo fuerte y robusto. Funciona construyendo secuencialmente modelos que corrigen los errores de los modelos anteriores, optimizando la función de pérdida a través de cada iteración. Esta técnica es eficaz para manejar la alta dimensionalidad y el ruido en los datos EEG, ya que mejora progresivamente la precisión del modelo.
- **Multi-Layer Perceptron:** Es una red neuronal que consiste en una capa de entrada, una o más capas ocultas y una capa de salida. Cada neurona en una capa está completamente conectada a las neuronas en la siguiente capa, permitiendo la captura de relaciones no lineales complejas entre las características de las señales EEG. Puede aprender patrones complejos en los datos, lo que es esencial para interpretar correctamente las variaciones sutiles en las señales cerebrales.
- **Convolutional Neural Network:** Las CNN son redes neuronales profundas que utilizan capas convolucionales para detectar patrones en los datos. Originalmente diseñadas para el procesamiento de imágenes, las CNN pueden adaptarse para trabajar con datos EEG transformando las señales en mapas espaciales o secuenciales. Esto permite capturar características espaciales y temporales cruciales para distinguir entre diferentes emociones en los registros EEG.
- **Long Short-Term Memory:** Diseñadas para aprender dependencias a largo plazo en secuencias de datos. Esto es crucial en análisis de EEG, donde el contexto temporal es importante para identificar correctamente un estado emocional. Las redes LSTM se compo-

nen de una estructura de celdas que controlan el flujo de información y permiten que el modelo retenga información relevante durante periodos prolongados.

3.1.6. Métricas de Clasificación

En el proceso de clasificación, se han empleado las siguientes métricas para evaluar la precisión y eficacia de los modelos: Precision, Recall, F1-Score y Support.

- **Precision:** Métrica que indica la proporción de verdaderos positivos frente al total de positivos predichos.

$$\text{Precision} = \frac{TP}{TP + FP}$$

donde TP son los verdaderos positivos y FP los falsos positivos.

- **Recall:** Mide la proporción de verdaderos positivos frente al total de positivos reales.

$$\text{Recall} = \frac{TP}{TP + FN}$$

donde TP son los verdaderos positivos y FN los falsos negativos.

- **F1-Score:** Media armónica de la precisión y el recall, proporcionando un balance entre ambas métricas.

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

- **Support:** Indica el número total de ocurrencias de cada clase en el conjunto de datos. Proporciona contexto sobre la distribución de las clases.

Support = número de casos reales para cada clase

- **Accuracy:** Proporción de predicciones correctas sobre el total de predicciones realizadas.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

donde TN son los verdaderos negativos y FN los falsos negativos.

Además de las métricas de rendimiento mencionadas anteriormente, se analizan las gráficas de pérdida y precisión para el conjunto de entrenamiento y validación a lo largo de las épocas del entrenamiento.

- **Loss:** La gráfica de pérdida muestra cómo el error del modelo disminuye a lo largo de las iteraciones de entrenamiento. Una disminución constante en la pérdida indica que el modelo está aprendiendo correctamente de los datos de entrenamiento.
- **Accuracy:** La gráfica de accuracy refleja la proporción de etiquetas que el modelo predice correctamente. Al observar esta métrica tanto en el conjunto de entrenamiento como en el de validación, se puede evaluar cómo se ajusta el modelo a los datos y su capacidad para generalizar a nuevas observaciones. Una alta precisión en ambos conjuntos indica que el modelo es efectivo y robusto.

3.2 Herramientas utilizadas

En el desarrollo de este trabajo, se han utilizado variedad de herramientas y bibliotecas ampliamente reconocidas en el ámbito del análisis de datos y el aprendizaje automático. A continuación, se presenta una visión general de las principales herramientas empleadas:

3.2.1. Python

Se han empleado varias bibliotecas de Python especializadas en el tratamiento de datos EEG y la construcción de modelos de clasificación.

- **MNE:** Biblioteca usada para el manejo y preprocesamiento de datos EEG. MNE ofrece herramientas avanzadas para la lectura, filtración, visualización y manipulación de señales neurofisiológicas. [24]
- **TensorFlow y Keras:** TensorFlow es la plataforma principal utilizada para construir y entrenar los modelos de aprendizaje profundo en este proyecto. Keras, facilita la creación de modelos complejos de redes neuronales convolucionales (CNN) y redes LSTM. [25]
- **PyTorch:** PyTorch también ha sido utilizado en ciertas etapas del proyecto para explorar arquitecturas alternativas de modelos y realizar pruebas adicionales. Es conocido por su facilidad de uso en el desarrollo de modelos de aprendizaje profundo, y ha sido útil en la experimentación con diferentes configuraciones de redes neuronales. [26]

3.2.2. Matlab. EEGLAB

EEGLAB es una herramienta de código abierto desarrollada como una extensión de MATLAB, que está específicamente diseñada para el análisis de datos EEG. Esta herramienta ofrece un conjunto de funciones avanzadas para el procesamiento de señales, incluyendo métodos de eliminación de artefactos, segmentación de datos o el análisis de componentes independientes (ICA). EEGLAB proporciona una interfaz gráfica intuitiva para la visualización y manipulación de los datos, esencial para las etapas del preprocesamiento. [27]

3.2.3. Cluster VRRAIN

Para llevar a cabo el entrenamiento y la optimización de los modelos de clasificación, se ha utilizado el Cluster VRRAIN de la UPV. Este cluster de computación de alto rendimiento está diseñado para ejecutar trabajos computacionalmente intensivos. Cuenta con nodos de computación con 8 GPUs NVIDIA A40, cada una con 48 GB de memoria. El sistema está gestionado por Slurm, un sistema de planificación que permite a los usuarios solicitar recursos específicos como CPUs y GPUs y ejecutar trabajos en uno o varios nodos del clúster. Para el desarrollo del trabajo en el cluster, se han utilizado entornos virtuales basados en Miniconda para gestionar las dependencias. Tensorflow se ejecutó en este entorno especializado para aprovechar las GPUs disponibles en el clúster, lo que ha permitido reducir considerablemente los tiempos de entrenamiento de los modelos.

3.3 Análisis del marco legal y ético

En el desarrollo de este proyecto, se ha puesto atención en cumplir con las regulaciones del Reglamento General de Protección de Datos (RGPD) [28] de la Unión Europea. Particularmente los artículos relevantes para la protección de datos sensibles en investigaciones científicas. El artículo 5 del RGPD establece los principios fundamentales del tratamiento de datos, que incluyen la legalidad, transparencia y limitación de la finalidad, asegurando que los datos personales se recojan para fines específicos, explícitos y legítimos. El artículo 6 detalla las bases legales para el tratamiento de datos, mientras que el artículo 9 comenta el tratamiento de categorías especiales de datos, como los datos de salud, relevantes en este estudio. Este marco

legal es crucial para garantizar que los datos personales y sensibles, como los gestionados en los experimentos para obtener los datos en este estudio, se manejen de la forma adecuada.

Para la utilización de la base de datos SEED-V del BCMI fue necesario aceptar y firmar un Acuerdo de Licencia de Usuario Final (EULA) que estipula las condiciones bajo las cuales estos datos pueden ser usados. Este acuerdo prohíbe explícitamente el uso comercial de los datos y limita su distribución y acceso a terceros, asegurando que solo se utilicen para propósitos de investigación académica, conforme a las cláusulas específicas del acuerdo.

Además de cumplir con la regulación sobre protección de datos, se ha utilizado un consentimiento informado de todos los participantes en este estudio. Este proceso garantiza que todos los participantes están plenamente informados de los objetivos del estudio, la naturaleza de las pruebas que se les realizarán, y a sus derechos a retirarse del estudio en cualquier momento. En el formulario de consentimiento informado se detallan los procedimientos involucrados, incluyendo la colocación de los electrodos para la recogida de señales EEG y la visualización de material audiovisual destinado a evocar respuestas emocionales. Este documento también reitera la protección de los datos recogidos, asegurando su anonimato y el uso exclusivo para fines de investigación.

En concordancia con los principios éticos de la investigación con seres humanos, este estudio se compromete a un uso ético de la información recogida, respetando la privacidad y la integridad de los participantes. Los datos recogidos son almacenados y procesados de manera anónima y que solo el equipo de investigación tiene acceso a ellos.

3.4 Solución propuesta

Para solucionar el desafío que es la predicción de emociones a partir de datos EEG, se ha diseñado una metodología que se desglosa en esta sección en sus pasos clave, los cuales se explicarán en detalle en los capítulos siguientes.

Inicialmente, una vez recopilados los datos, han sido sometidos a un tratamiento preliminar que trata de incluir en el análisis solo los datos válidos. Esto quiere decir que se han implementado técnicas sobre los datos para descartar aquellos segmentos que han generado datos EEG que no son relevantes. Este tratamiento preliminar incluye la segmentación de los datos en diferentes datasets para facilitar su manipulación y análisis.

El siguiente paso para la solución del problema es una de las principales propuestas en el trabajo: el desarrollo e implementación de un algoritmo de preprocesamiento de señales. Este algoritmo, fundamentado en las herramientas y conceptos discutidos en el marco teórico, aplica las diferentes técnicas explicadas previamente. Este paso trata de ser un valor añadido significativo respecto a estudios previos, al mejorar la calidad de los datos que serán utilizados para la clasificación de emociones.

Con los datos procesados, se procede a la aplicación de diversos modelos de aprendizaje automático y aprendizaje profundo. Este paso tiene como objetivo evaluar la capacidad de estos modelos para predecir emociones basadas en los datos EEG. Además, se realizará una comparativa entre los resultados obtenidos con los datos originales sin procesar y los datos procesados para determinar la eficacia del algoritmo.

Finalmente, la metodología incluye una fase de despliegue y aplicación donde se probarán los modelos que hayan tenido mejor desempeño sobre un nuevo conjunto de datos EEG recogidos específicamente para este propósito. Este experimento adicional tiene como objetivo evaluar la robustez de los modelos y solucionar los problemas de aplicabilidad en situaciones reales que se puedan presentar.

Cada uno de estos pasos contribuye a la construcción de una solución general que aborda todos los retos del reconocimiento de emociones mediante señales de EEG. La efectividad de esta solución propuesta es discutida en profundidad en las siguientes secciones del estudio.

CAPÍTULO 4

Preparación y Comprensión de los Datos

4.1 SEED V Dataset

El conjunto de datos utilizado ha sido el SEED-V, que forma parte de la serie de conjuntos de datos SEED proporcionados por el BCMI (Brain-Computer Interface and Machine Learning) Lab de la Universidad de Shanghai Jiao Tong. Este conjunto de datos es ampliamente reconocido en la investigación de interfaces cerebro-computadora (BCI) y en el análisis de emociones a partir de señales EEG. Está diseñado específicamente para la investigación en el reconocimiento de las emociones humanas. Incluye señales EEG de múltiples sujetos mientras visualizaban videos que evocan distintas respuestas emocionales.

El SEED-V utiliza un método de inducción de emociones basado en clips de vídeo diseñados para evocar respuestas emocionales particulares. Cada uno de los 16 participantes del estudio, asistió a tres sesiones de experimentación y entre sesiones se dejaron intervalos de tres días para evitar sesgos en las respuestas. Durante cada sesión, los participantes vieron 15 vídeos diferentes, con intervalos de duración variable entre vídeos y 3 de los vídeos de cada sesión están asignados a cada una de las 5 categorías emocionales: felicidad, tristeza, asco, miedo y neutralidad.

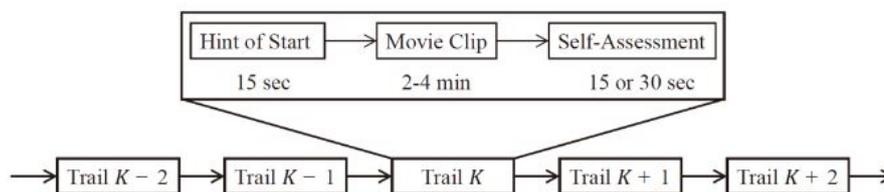


Figura 4.1: Procedimiento de visualización de vídeos.

[23]

Los datos se recogieron utilizando un sistema EEG Neuroscan de 66 canales. Un sistema que permite la grabación de actividad eléctrica cerebral con alta resolución espacial y temporal, utilizando 66 electrodos colocados en el cuero cabelludo del sujeto.

A continuación, se detalla el contenido y la estructura de los datos disponibles proporcionados por el BCMI.

- **Carpeta EEG DE Features:** Esta carpeta contiene características extraídas de la señal de cada uno de los 16 participantes.
- **Carpeta EEG raw:** Contiene los datos EEG brutos recopilados con el dispositivo Neuroscan, almacenados en archivos con formato ".cnt". Proporciona los datos para cada individuo en cada sesión, en total, 48 archivos de datos.
- **Carpeta SRC:** Contiene subcarpetas con modelos y códigos utilizados en investigaciones relacionadas.
- **Archivo trial start end timestamp.txt:** Documenta los tiempos de inicio y fin de los clips de vídeo en cada sesión, esenciales para seleccionar los datos de interés en cada experimento y descartar los intervalos entre vídeos que no suscitan ninguna emoción.
- **Archivo emotion label and stimuli order.xlsx:** Contiene el orden de los vídeos presentados a los participantes en cada sesión junto a la emoción relacionada con ese vídeo.
- **Archivo Participants info.xlsx:** Ofrece información sobre los sujetos involucrados en el estudio.
- **Archivo Scores.xlsx:** Recoge las puntuaciones de feedback proporcionadas por los participantes, evaluando la efectividad de cada estímulo en inducir la emoción deseada.
- **Archivo Channel 62 Pos.locs:** Contiene las localizaciones de los canales utilizados.

El estudio se ha centrado principalmente en la utilización de los datos EEG brutos, complementados con la información de los archivos con los tiempos de inicio y final, y el de etiquetas, necesarios para alinear de manera precisa los estímulos emocionales generados por los videos y las señales EEG capturadas y un correcto etiquetado de las emociones en cada segmento de datos. Aunque el conjunto de datos incluye también características extraídas de las señales y modelos de clasificación, he optado por desarrollar y extraer mis propias características y modelos a partir de los datos EEG brutos para ajustarlas específicamente a los objetivos de mi estudio, por lo que esas carpetas no han sido utilizadas.

4.2 Preprocesamiento. EEGLAB Pipeline

Antes de comenzar con el preprocesamiento y análisis detallado de los datos EEG, se ha llevado a cabo un paso crucial para preparar adecuadamente los datos para el estudio. Este primer paso consiste en separar cada uno de los archivos de datos en crudo, correspondientes a las sesiones de los 16 individuos participantes, en 15 archivos distintos, uno por cada video visualizado. En total, se procesaron los 48 archivos (16 individuos x 3 sesiones), para generar 720 archivos de datos EEG (48 archivos x 15 videos visualizados).

La razón detrás de esta segmentación fue eliminar los datos registrados durante los intervalos de diferente duración que ocurren entre el final de un video y el inicio del siguiente. Este tiempo intermedio, destinado a permitir una breve fase de descanso, no es relevante para el análisis de las respuestas emocionales inducidas por los videos. Para lograr esta segmentación precisa, se utiliza el archivo que contiene los tiempos de inicio y fin de cada clip de video, permitiendo excluir los periodos de inactividad entre videos.

Aquí se representa visualmente la extracción de los segmentos correspondientes a cada video en cada sesión. Como se ha comentado, en cada sesión se presentan unos videos diferentes para mejorar el experimento, por lo que las duraciones son diferentes.

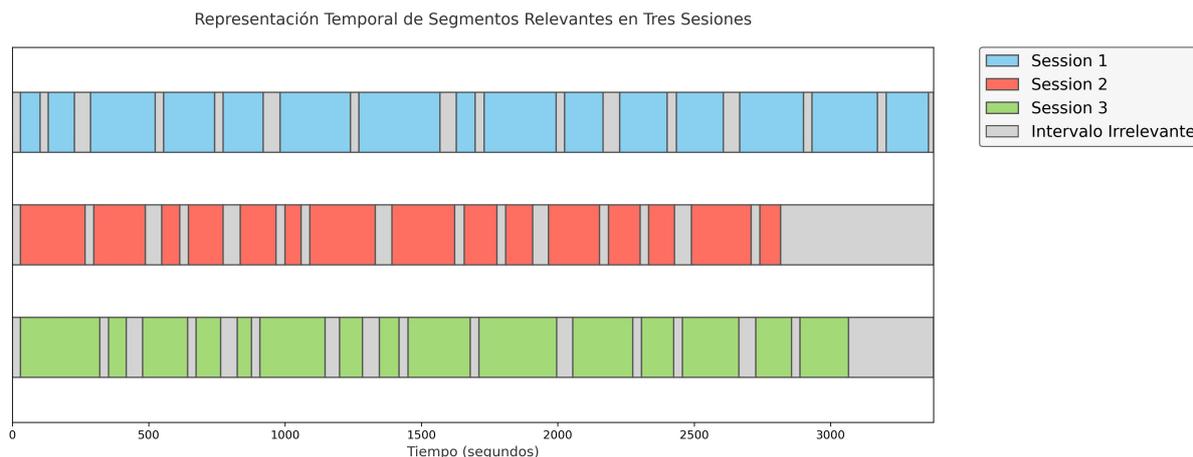


Figura 4.2: Segmentos de interés de cada sesión.

Durante la segmentación de los datos se realizó el paso de resamplado de los datos EEG a 400Hz para optimizar los cálculos posteriores usando la biblioteca MNE de Python. Originalmente, los datos estaban recogidos con una frecuencia de muestreo de 1000Hz, lo que implica 1000 puntos de datos por segundo por canal. Esta alta frecuencia de muestreo captura una gran cantidad de información, pero también implica una carga computacional muy alta. El resamplado a 400Hz mejora la eficiencia sin comprometer la integridad de la información ya que es una frecuencia típicamente usada en estudios de EEG.

En el desarrollo del algoritmo de preprocesamiento de los datos EEG se estableció un flujo de trabajo específico que ha demostrado ser el más efectivo en términos de calidad de los datos resultantes. Este procedimiento, ilustrado en el diagrama de flujo, ha sido diseñado para maximizar la eficiencia del preprocesamiento y la precisión en la detección de artefactos.

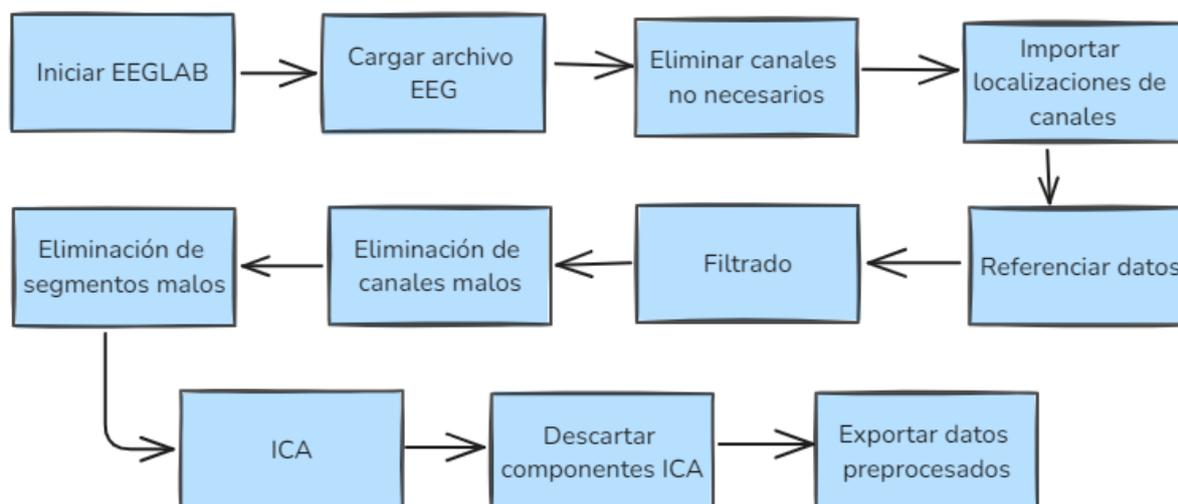


Figura 4.3: Pipeline de Procesamiento en EEGLAB

El proceso comienza con la carga de archivos EEG, seguido de la eliminación de canales innecesarios. Esta eliminación temprana es necesaria cuando se trabaja con canales que registran información no cerebral o que se usan como referencia, por eso se ubica en los primeros pasos. La importación de las localizaciones de los canales a continuación permite una interpretación espacial de las señales, necesaria para análisis posteriores. El referenciado de los datos antes

de aplicar cualquier tipo de herramienta asegura que cualquier ajuste o modificación se realice sobre una base común y estandarizada. El filtrado inicial aprovecha esta base estandarizada para limpiar eficazmente la señal de frecuencias no deseadas o ruido externo. Una vez realizado el primer filtrado, se aplican la eliminación de canales y segmentos malos, lo que maximiza la efectividad del ICA para identificar fuentes independientes en la señal, ya que trabaja sobre un conjunto de datos más limpio y organizado.

Este orden de operaciones garantiza que cada paso del procesamiento se construya sobre los avances del paso anterior, mejorando la calidad y fiabilidad del estudio. La justificación de esta secuencia está respaldada por pruebas que han demostrado que seguir este orden en particular proporciona unos mejores resultados para el análisis emocional con EEG.

El algoritmo de Matlab diseñado en este estudio, que puede encontrarse en el [Apéndice A2](#) utiliza todos los archivos EEG obtenidos y aplica de manera automática cada uno de estos procedimientos. Para explicar cada uno de ellos, tomaremos un archivo único como ejemplo y se replicará el proceso del algoritmo.

El primer paso en el proceso es la carga de los datos desde un archivo .cnt en EEGLAB.

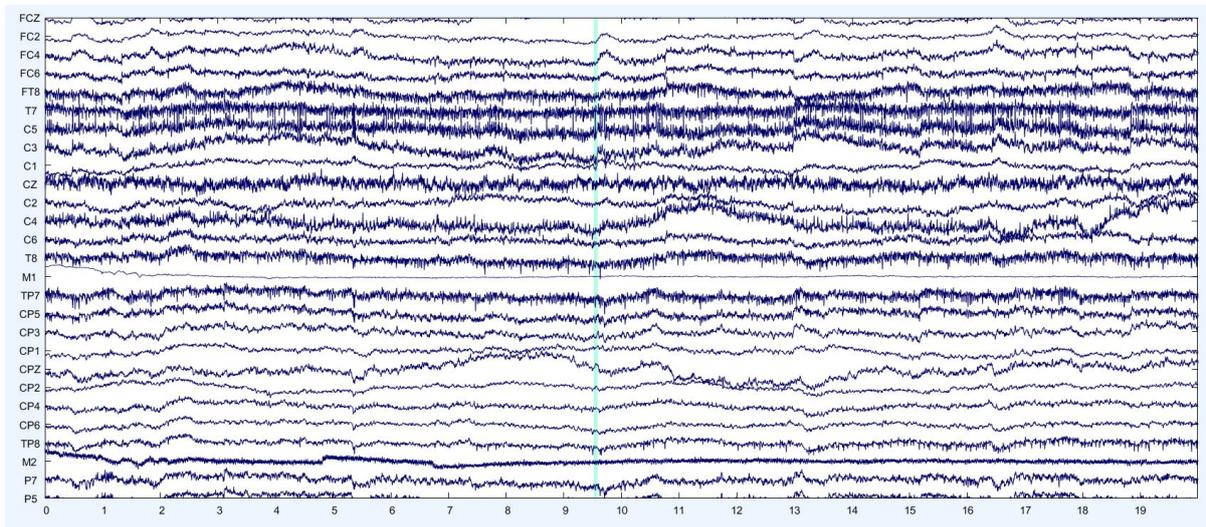


Figura 4.4: Ejemplo EEG crudo.

Al cargar los datos se genera una visualización inicial que muestra las señales EEG tal y como fueron adquiridas. Los canales están organizados en filas, cada uno representando un electrodo específico colocado en el cuero cabelludo del sujeto. Se pueden observar variaciones en la amplitud y la frecuencia de las ondas a lo largo de los diferentes canales. En la imagen se representan las señales de 20 canales durante los primeros 20 segundos de un experimento, para facilitar la visualización.

Ahora se deben eliminar los canales que no son relevantes para el análisis. Estos canales suelen incluir los que capturan movimientos oculares *VEO*, *HEO* y canales de referencia o mastoides *M1*, *M2*. Estos canales no representan la actividad cerebral directamente. Aquí se detalla la función de cada uno.

- **VEO y HEO:** Capturan los movimientos oculares en el plano vertical y horizontal respectivamente, y parpadeos. En este caso generan artefactos no relacionados con la actividad cerebral.
- **M1 y M2 (Mastoides):** Estos canales suelen ser utilizados como referencias y no contienen información relevante para el análisis cerebral.

Después de la eliminación de los canales irrelevantes, se importan las ubicaciones de los electrodos. Esto es esencial para asegurar que el análisis de los datos EEG se realice con una correcta representación espacial. Con la importación de canales, se aplica la referencia promedio de esos canales, lo que permite reducir el ruido común, facilitar la comparación entre canales y normalizar la señal.

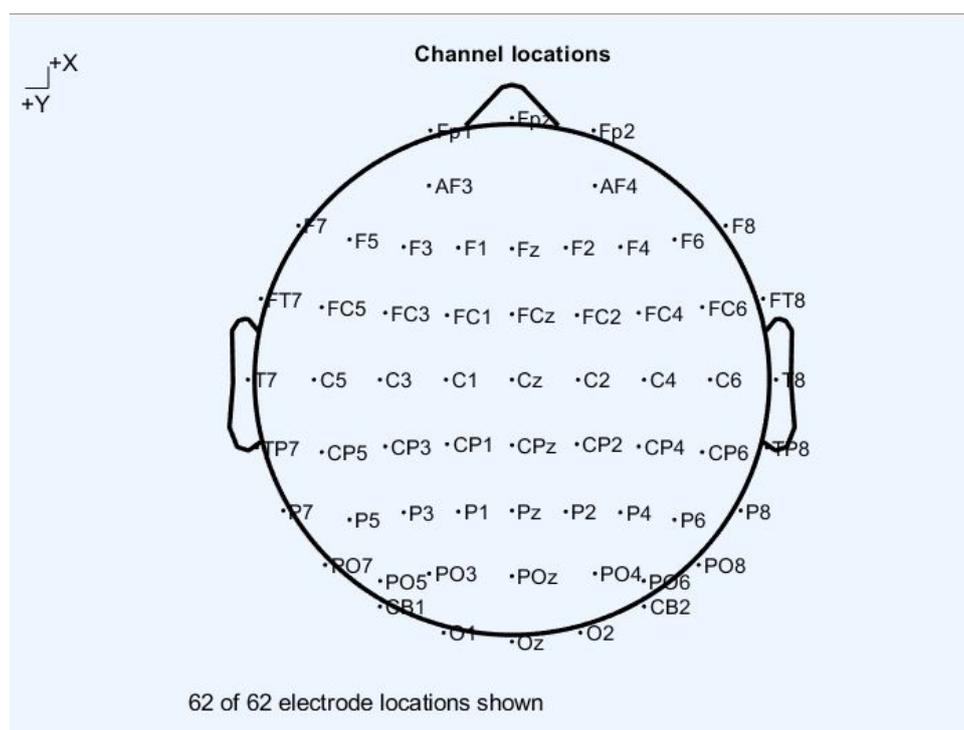


Figura 4.5: Representación de los 62 canales utilizados.

El siguiente paso en el preprocesamiento es aplicar el filtrado de paso banda a los datos EEG. Este filtro permite conservar las frecuencias de interés y eliminar las que están fuera del rango deseado, que a menudo corresponden a artefactos o ruido. La frecuencia de corte baja se establece en 0.5 Hz, para eliminar componentes de muy baja frecuencia que generalmente están asociados con artefactos de movimiento. Estas frecuencias tan bajas no suelen ser de interés en el análisis EEG, que se enfoca más en las bandas de frecuencia como Delta (1-4Hz), Theta (4-8Hz), Alpha (8-12Hz), Beta (13-30Hz) y Gamma (>30 Hz). La frecuencia de corte alta se establece en 70 Hz, para eliminar las frecuencias que a menudo están contaminadas por ruido electromagnético y otros artefactos de alta frecuencia. Estas frecuencias altas suelen contener poco contenido informativo útil en la mayoría de los análisis de EEG.

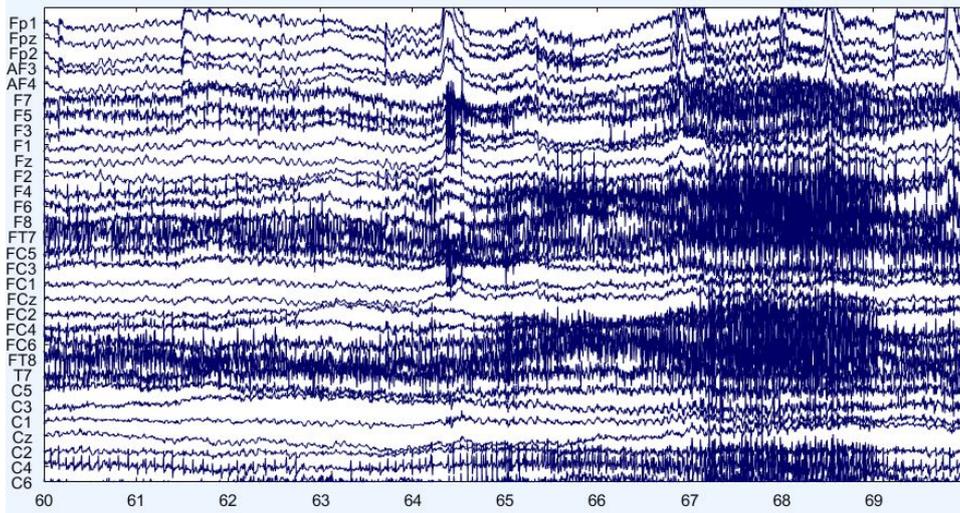


Figura 4.6: EEG previo al filtrado.

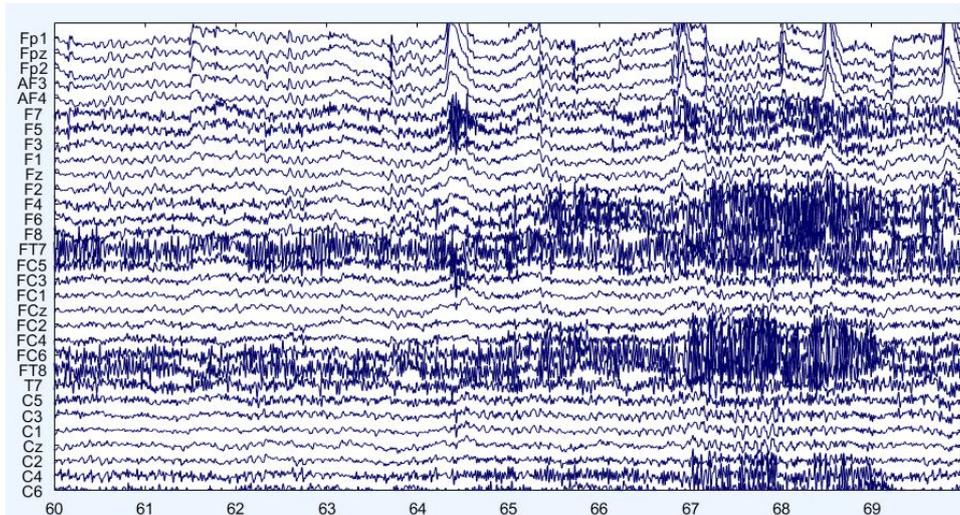


Figura 4.7: EEG filtrado.

Se observa una mejora significativa en la calidad de la señal. Antes del filtrado, se aprecian oscilaciones rápidas que sugieren la presencia de ruido electromagnético o interferencias. Estos elementos son efectivamente atenuados con el filtrado, lo que resulta en una señal más clara y centrada en las bandas de frecuencia relevantes para el análisis.

En el proceso de identificación y eliminación de canales defectuosos, se aplica el algoritmo de eliminación de canales basado en la probabilidad de que ese canal sea defectuoso. Un canal defectuoso puede darse por un mal contacto de los electrodos, ruido excesivo o interferencias.

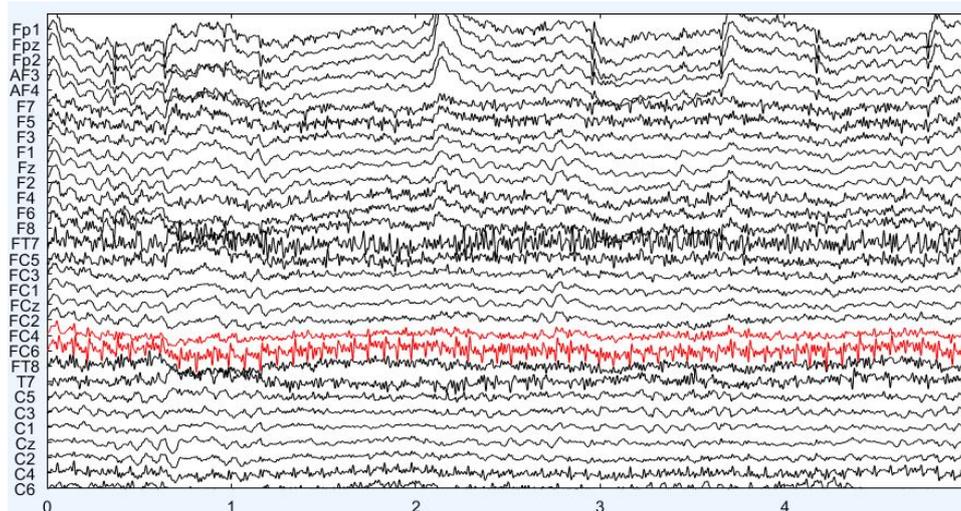


Figura 4.8: Posibles canales defectuosos.

Podemos observar los gráficos de espectro de potencia para esos canales *FC4* y *FC6* para estudiar si existen irregularidades significativas en la distribución de frecuencias. Se presenta también un canal no defectuoso, para comparar.

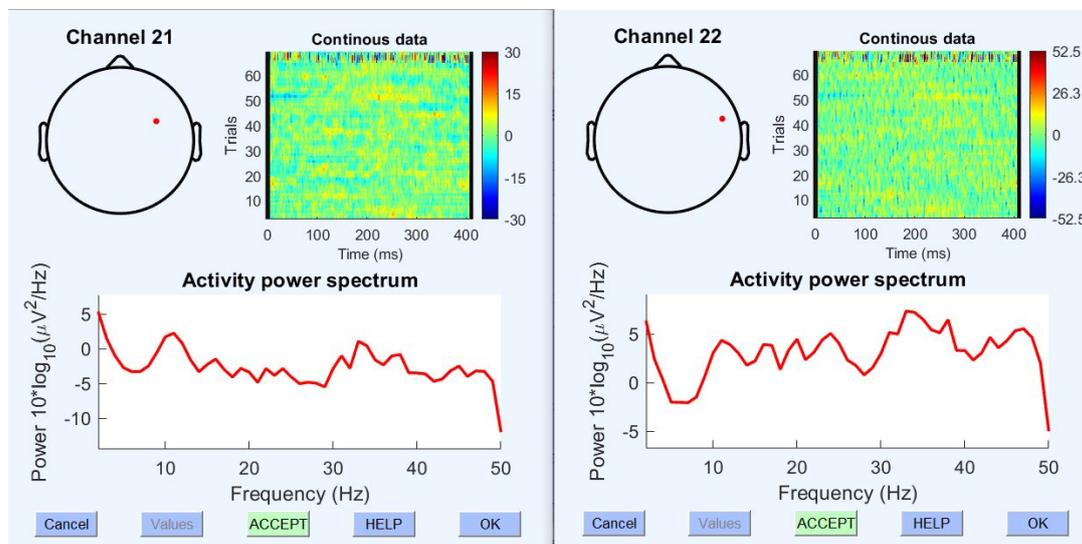


Figura 4.9: Posibles canales defectuosos.

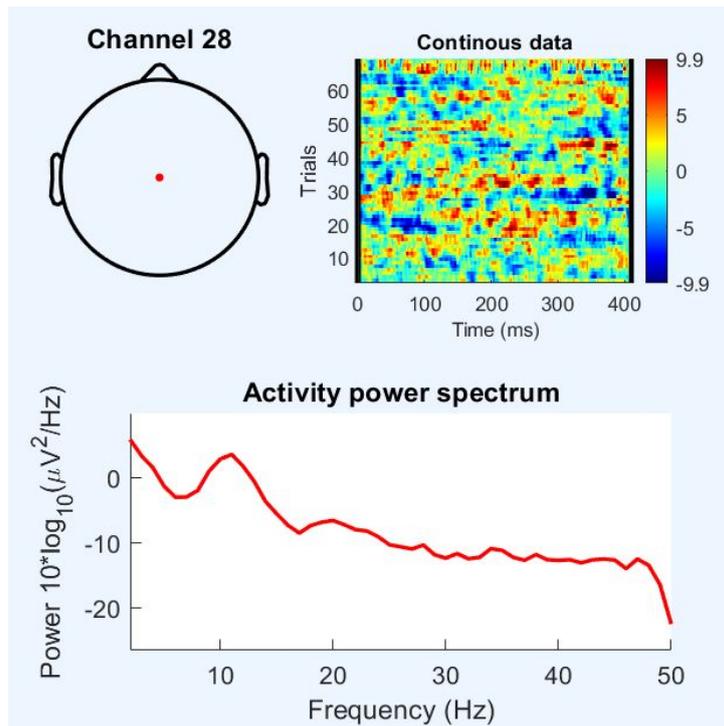


Figura 4.10: Canal no defectuoso.

Observando los gráficos de espectro de potencia para los canales FC4 y FC6, podemos ver irregularidades significativas en la distribución de potencias, con oscilaciones atípicas y picos, lo que sugiere la presencia de artefactos. La variabilidad en la potencia también es mayor de lo esperado. El canal CZ (Channel 28), muestra un espectro de potencia normal, estable y consistente. Las frecuencias están distribuidas de manera uniforme y no hay picos anómalos. Esto es típico de un canal que está capturando señales EEG de buena calidad.

Antes de proceder con el análisis de componentes independientes (ICA), es esencial eliminar los segmentos continuos de datos que contengan artefactos muy marcados, como movimientos bruscos del sujeto.

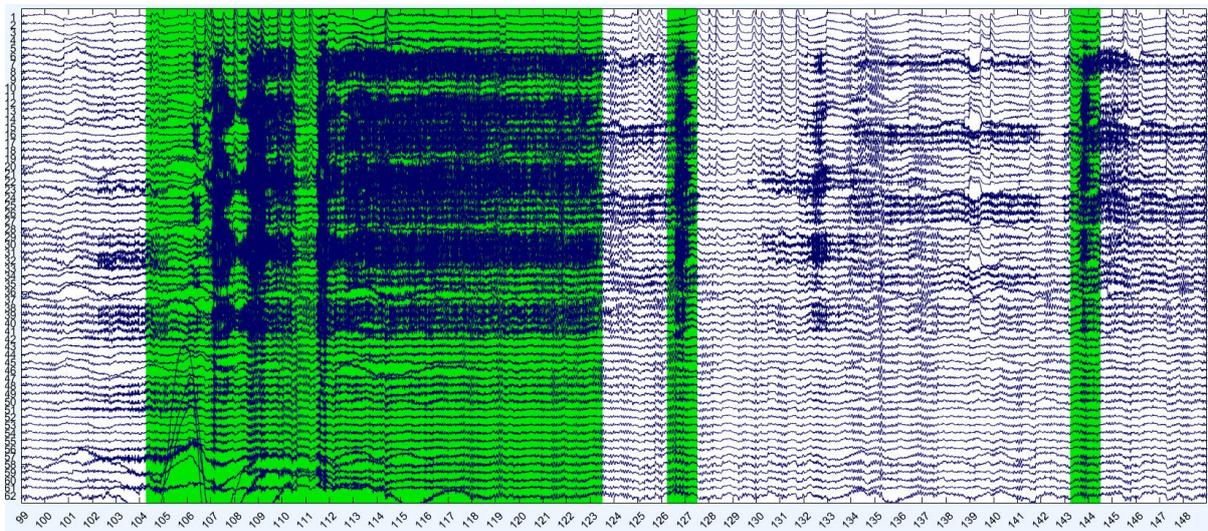


Figura 4.11: Segmentos de datos no validos.

Las áreas en verde indican los segmentos que han sido identificados como defectuosos y por tanto eliminados. Estos segmentos muestran picos de alta amplitud y patrones caóticos que son característicos de artefactos significativos. Entre el segundo 104 y 115 por ejemplo, se observa un segmento de datos con múltiples artefactos distribuidos a través de varios canales. Este paso es importante para técnicas como el ICA, que pueden ser altamente sensibles a artefactos de alta amplitud.

Posteriormente se aplica el ICA, una técnica que separa una señal multivariada en sus componentes independientes. Esto permite identificar y separar las componentes que se corresponden a artefactos como movimientos oculares, actividad muscular o ruido de la señal eléctrica. Al aplicar el ICA, se clasifica cada una de las componentes en diferentes categorías. La herramienta integrada de ICA en EEGLAB proporciona un valor indicativo de el peso de cada categoría en esa componente de la señal. Las diferentes categorías son: *Brain*, *Muscle*, *Eye*, *Heart*, *Line Noise* y *Channel Noise*. Para la visualización de estas componentes, se muestran mapas topográficos para cada componente, indicando el valor comentado. Por ejemplo, una componente etiquetada como *Muscle* con un valor alto, indica que la mayor parte de la señal proviene de actividad muscular y por tanto debería ser eliminada. En el diseño del algoritmo de preprocesado, se ha establecido que aquellas componentes con más de un 70 % proveniente de alguna categoría que no sea cerebral se deben eliminar automáticamente.

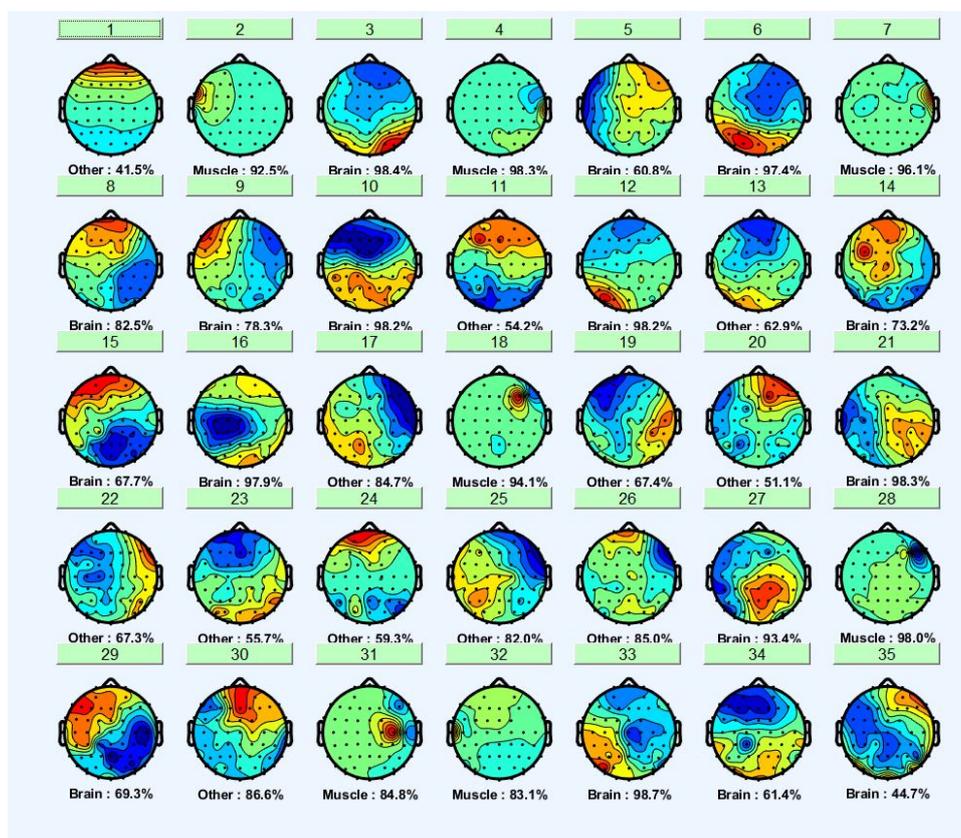


Figura 4.12: Resultados del ICA 1.

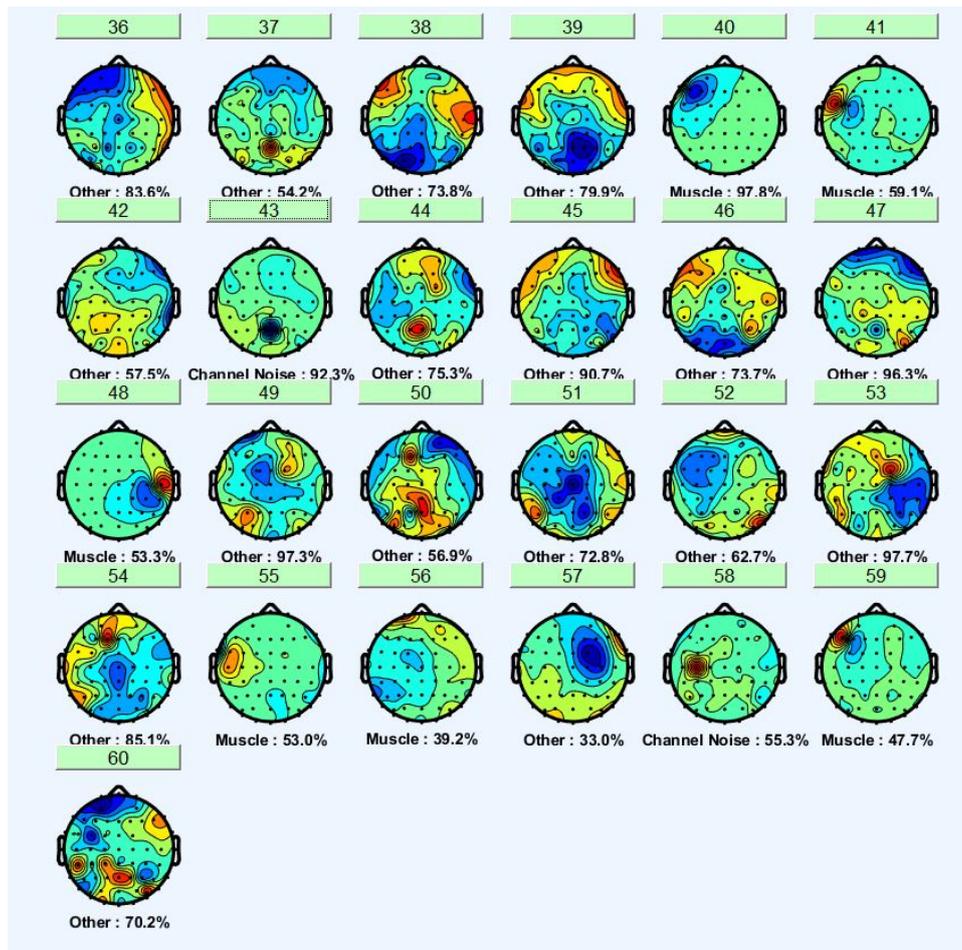


Figura 4.13: Resultados del ICA 2.

Con los resultados del ICA se puede observar la localización de procedencia de cada componente de la señal. La descomposición de la señal permite analizar por separado cada componente, como se ha generado y su localización en la estructura cerebral. Por ejemplo, se puede ver como en la componente número 3 se captura señal procedente del cerebro sin apenas ruido ni artefactos y en concreto procedente de los electrodos situados en la parte occipital del cerebro. Componentes como la 2, la 7 o la 18, capturan componentes de la señal producidos por movimientos musculares en ciertos electrodos muy específicos. Análizando cada una de las componentes se pueden definir cuáles son de relevancia para el estudio y cuáles hay que descartar por no proceder de señales cerebrales.

Finalmente, tras eliminar las componentes con alto valor no cerebral, obtenemos la señal EEG preprocesada. Aquí se muestra la señal que se había presentado al principio de esta sección tras la aplicación del algoritmo de procesado.

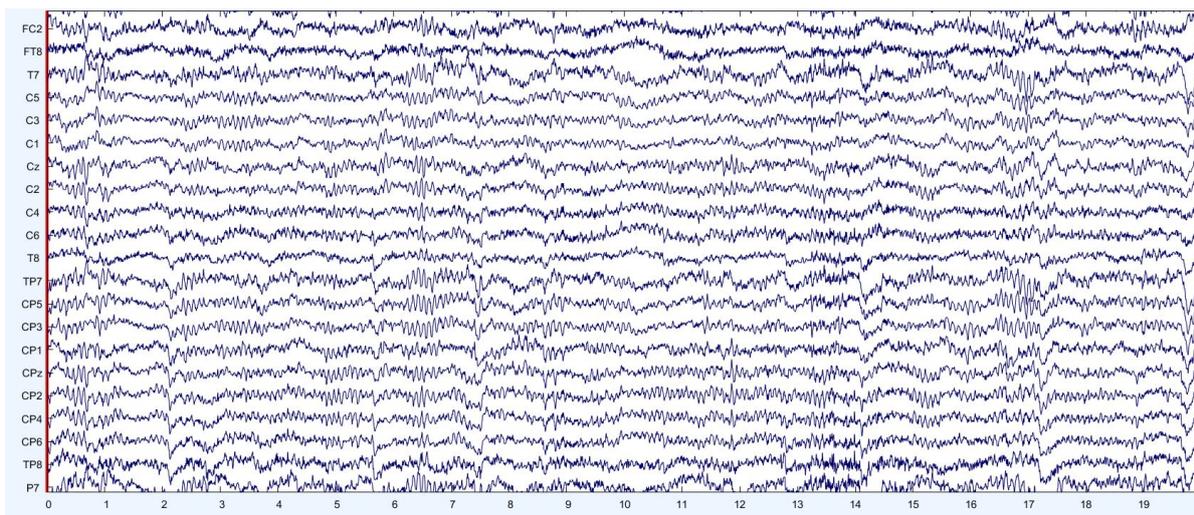


Figura 4.14: Aplicación del algoritmo de procesamiento sobre una señal EEG en crudo.

4.3 Extracción de características

La extracción de características permite obtener información de la señal en un formato más adecuado para el uso en algoritmos de clasificación. Este proceso involucra técnicas estadísticas y de procesamiento de señales para identificar y cuantificar los elementos que reflejan las propiedades de la señal EEG. Se ha desarrollado un script en Python, que puede encontrarse en el [Apéndice A3](#) que con el uso de la librería MNE, extrae eficazmente las características de entropía de la señal, que serán usadas posteriormente para clasificar los estados emocionales.

Antes de la extracción de características, es esencial preparar los datos EEG para garantizar la consistencia en todo el conjunto de datos. Debido a que en el algoritmo de preprocesamiento se ha implementado un método de eliminación automática de canales considerados malos, el número de canales de los datasets es variable. Para solucionar este problema, se añaden canales sintéticos en aquellos datasets con menos de 62 canales. Estos canales sintéticos se crean a partir de los valores medios del resto de canales.

La extracción de características se centró en el cálculo de la entropía diferencial (DE) a partir de la transformada de Fourier de tiempo corto (STFT), utilizando ventanas de Hanning de 4 segundos sin solapamiento. Este método se aplicó a las cinco bandas de frecuencia establecidas: delta (1-4 Hz), theta (4-8 Hz), alpha (8-14 Hz), beta (14-31 Hz) y gamma (31-50 Hz). Cada archivo generado en el preprocesamiento, es segmentado en épocas de 4 segundos, calculando las características DE para cada canal en cada época. Esto resulta en archivos de 310 características por época (62 canales x 5 bandas de frecuencia). El número de filas de cada dataset de características corresponde al número de épocas de 4 segundos que se puedan extraer, dependiendo de la duración del video.

Una vez generadas las características de cada dataset, se añade su correspondiente etiqueta de emoción. Cada dataset contiene la señal generada a partir de determinado video en determinado ensayo. En función del número del ensayo y el número del video, se añade automáticamente la etiqueta de emoción correspondiente. Para este último paso se utiliza el archivo *emotion label and stimuli order* que contiene el orden de los videos presentados en cada sesión con la etiqueta emocional relacionada a ese video.

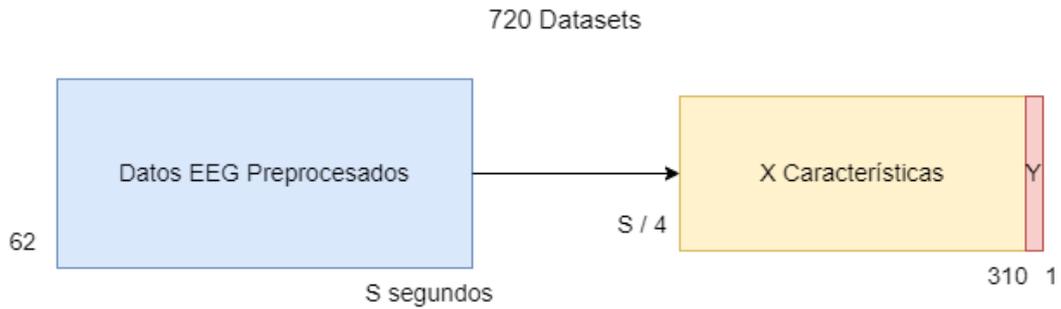


Figura 4.15: Dimensiones de un dataset tras la extracción de features.

Finalmente se realiza un mapeo de las etiquetas emocionales a valores numéricos y se combinan todos los datos en un único DataFrame para facilitar su manipulación y análisis en los procesos de aprendizaje automático. Este DataFrame incluye todas las características extraídas junto con las etiquetas numéricas de las emociones, proporcionando una base de datos robusta y estructurada adecuadamente para la exploración de correlaciones entre características de EEG y estados emocionales.

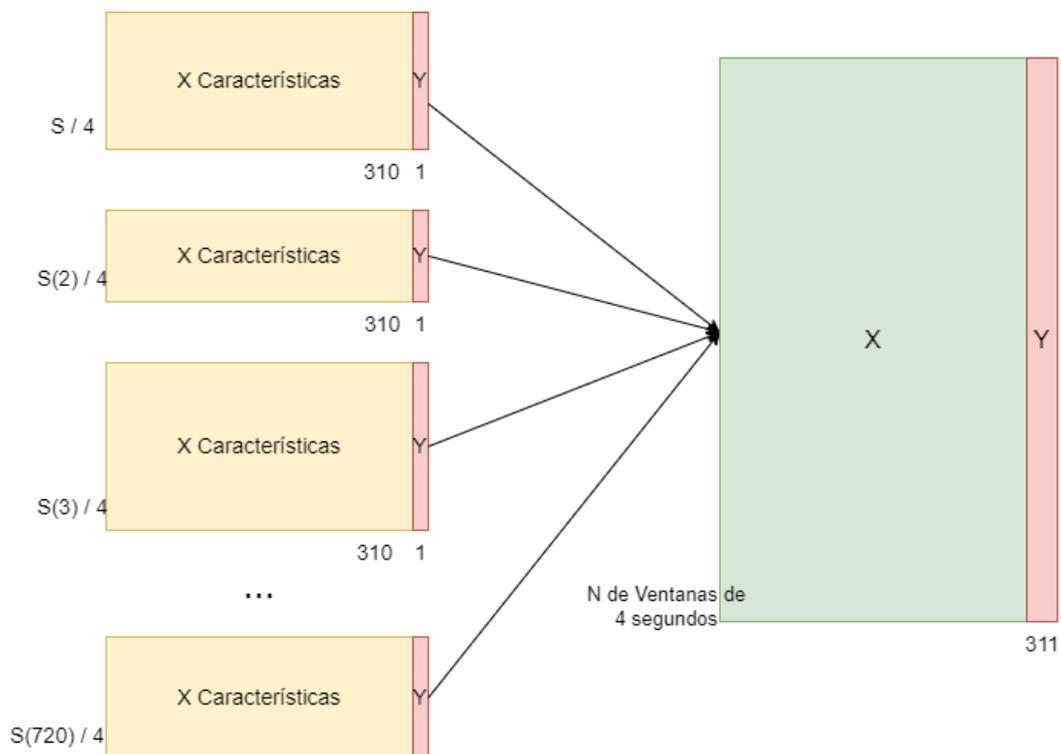


Figura 4.16: Dimensiones del dataset final.

CAPÍTULO 5

Evaluación y Validación de los Modelos

El propósito de esta sección es evaluar la eficacia de diversos modelos de clasificación en la tarea de predecir emociones a partir de datos EEG. El enfoque se centra en la comparación de los resultados obtenidos de modelos aplicados a tres conjuntos de datos, todos con la misma información pero cada uno con un nivel diferente de preprocesamiento. Este análisis permite determinar la importancia del preprocesamiento y la extracción de características en la precisión de la clasificación de emociones, así como estudiar el mejor modelo con los parámetros óptimos para clasificar emociones a partir de EEG.

Para llevar a cabo este estudio, se ha empleado el mismo dataset de EEG (SEED-V), cada uno preparado bajo condiciones diferentes:

- **Dataset sin procesar. Datos EEG en crudo:** El primer conjunto de datos consiste en las señales EEG registradas directamente, sin ningún tipo de preprocesamiento o extracción de características. La intención inicial era determinar si modelos de aprendizaje profundo avanzados, como las redes neuronales convolucionales (CNN) y las de memoria a corto y largo plazo (LSTM), eran capaces de identificar automáticamente las características relevantes y los patrones a partir de los datos en bruto. Los resultados obtenidos con este dataset fueron considerablemente inferiores, lo que sugiere que la ausencia de procesamiento y la complejidad de los datos en crudo limitan la capacidad de los modelos para realizar predicciones precisas. Debido a los resultados poco prometedores, este dataset no se discutirá en detalle.
- **Dataset sin limpieza de señales:** Este dataset fue preparado sin realizar una limpieza previa de las señales EEG. Directamente desde su forma original, se extrajeron características basadas en la entropía diferencial, un método bien documentado en la literatura para la clasificación de emociones. Esta aproximación sigue el método empleado en estudios previos, como el de Liu et al. [23], y sirve como punto intermedio entre el uso de datos en bruto y datos completamente procesados.
- **Dataset procesado con EEGLAB:** En este caso, el dataset fue procesado utilizando el algoritmo previamente explicado diseñado en Matlab, haciendo uso de las herramientas de la librería EEGLAB. Este proceso incluye las etapas de filtrado y descomposición de las señales, como se ha comentado en secciones anteriores, y la extracción de características. Este enfoque pretende preparar los datos de manera que se maximice la información relevante y se eliminen los datos incluidos en el EEG que no pertenecen a información cerebral.

Antes de proceder con la evaluación de los modelos, se realizó una preparación de los datos que incluye la división en conjuntos de entrenamiento y prueba, así como el escalado de características. Para ambos conjuntos de datos, se aplicó una división estratificada en una proporción de 80 % para entrenamiento y 20 % para prueba, manteniendo la distribución original de las clases. Adicionalmente se realizó un escalado estandar sobre las características de ambos conjuntos de datos.

Se seleccionaron cuatro modelos de clasificación para esta evaluación: **Gradient Boosting (GB)**, **Perceptrón Multicapa (MLP)**, **Red Neuronal Convolutiva (CNN)** y **Red Neuronal de Memoria a Corto y Largo Plazo (LSTM)**. Estos modelos se eligieron por su capacidad demostrada en tareas de clasificación de emociones y su potencial para manejar la complejidad de los datos EEG. Para optimizar el rendimiento de cada modelo, se aplicó la estrategia de *Grid Search*. Esta técnica permite buscar de manera exhaustiva los mejores parámetros para el modelo a través de un espacio de *hiperparámetros* definidos, seleccionando la combinación que ofrece el mejor rendimiento según una métrica específica, en este caso, la precisión (*accuracy*).

La siguiente tabla resume los resultados de precisión obtenidos para cada uno de los modelos en ambos datasets:

Modelo	Dataset sin EEGLAB	Dataset con EEGLAB
Gradient Boosting	0.508	0.850
MLP	0.627	0.823
CNN	0.491	0.911
LSTM	0.597	0.880

Tabla 5.1: Comparativa de precisión entre modelos y datasets.

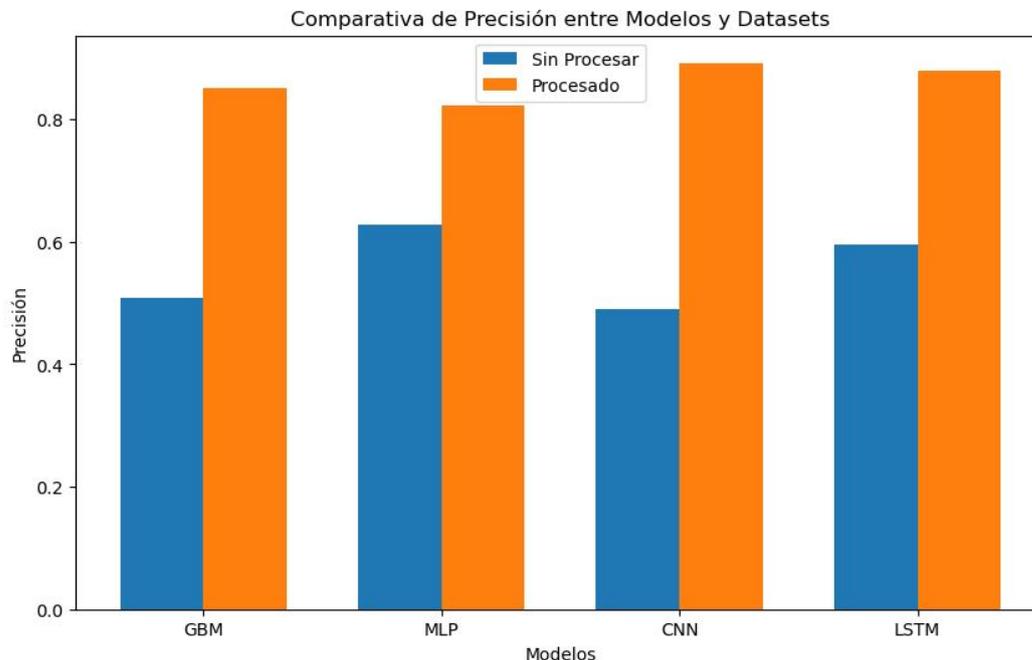


Figura 5.1: Comparativa gráfica de los modelos.

A partir de estos resultados, se observa una mejora general en la precisión cuando se utilizan los datos preprocesados con EEGLAB, lo cual indica la importancia del preprocesamiento en la clasificación de emociones a partir de EEG.

De los modelos evaluados, CNN y LSTM destacan como los más eficaces cuando se utiliza el dataset preprocesado con EEGLAB. A continuación se analizan en detalle ambos modelos, en cuanto a arquitectura, hiperparámetros y mejoras.

5.1 Modelo CNN

El modelo de red convolucional desarrollado sigue una estructura jerárquica que comienza con capas convolucionales 2D, de manera similar a lo realizado en el estudio de Wang *et al.*[29]. Los datos de entrada con dimensiones (10, 31, 1), donde 10 corresponde a ventanas temporales y 31 a las características. Aquí se describen los componentes principales de la arquitectura:

- **Capas Convolucionales:** El modelo se inicia con tres capas convolucionales 2D. La primera capa tiene 32 filtros con un tamaño de *kernel* de 3x3, seguidos por capas con 64 y 128 filtros, respectivamente. Cada capa convolucional utiliza la función de activación ReLU y aplica un padding *same* para mantener las dimensiones espaciales y temporales a través del modelo.
- **Capas de Normalización por Lotes (*Batch Normalization*):** Después de cada capa convolucional, se aplica una normalización por lotes para estabilizar y acelerar el proceso de entrenamiento.
- **Capas de *Max-Pooling*:** Para reducir la dimensionalidad temporal y controlar el sobreajuste se aplican capas de *max-pooling* con un tamaño de *pool* 2x2 y padding *same*.
- **Capas de *Dropout*:** Se añaden capas de *dropout* después de cada bloque convolucional y después de la capa densa para prevenir el sobreajuste, con tasas de *dropout* de 0.25 en las capas convolucionales y 0.5 en la capa densa.
- **Capa Densa:** Tras la operación de aplanado (*flatten*), se emplea una capa densa de 256 neuronas con activación ReLU, seguida de una capa de normalización por lotes y una última capa de *dropout*.
- **Capa de Salida:** Finalmente, la capa de salida utiliza la función de activación softmax para producir probabilidades de pertenencia a cada una de las 5 clases emocionales.

Layer Type	Output Shape	Parameters
Input	(10, 31, 1)	-
Conv2D	(10, 31, 32)	32 filters, 3×3 , ReLU, same padding
BatchNormalization	(10, 31, 32)	-
MaxPooling2D	(5, 16, 32)	Pool size: 2×2 , same padding
Dropout	(5, 16, 32)	Dropout rate: 0.25
Conv2D	(5, 16, 64)	64 filters, 3×3 , ReLU, same padding
BatchNormalization	(5, 16, 64)	-
MaxPooling2D	(3, 8, 64)	Pool size: 2×2 , same padding
Dropout	(3, 8, 64)	Dropout rate: 0.25
Conv2D	(3, 8, 128)	128 filters, 3×3 , ReLU, same padding
BatchNormalization	(3, 8, 128)	-
MaxPooling2D	(2, 4, 128)	Pool size: 2×2 , same padding
Dropout	(2, 4, 128)	Dropout rate: 0.25
Flatten	(1024)	-
Dense	(256)	256 units, ReLU, L2 regularization
BatchNormalization	(256)	-
Dropout	(256)	Dropout rate: 0.5
Output (Dense)	(5)	5 units, Softmax

Tabla 5.2: Arquitectura del Modelo CNN

Durante el entrenamiento se empleó el optimizador Adam con una tasa de aprendizaje del 0.0001 para acelerar la convergencia. Para evitar el sobreajuste y mejorar el rendimiento, se implementó *EarlyStopping* con paciencia de 10 épocas, junto con *ReduceLROnPlateau* para disminuir la tasa de aprendizaje en un factor de 0.5 si no se observaban mejoras en la pérdida de validación.

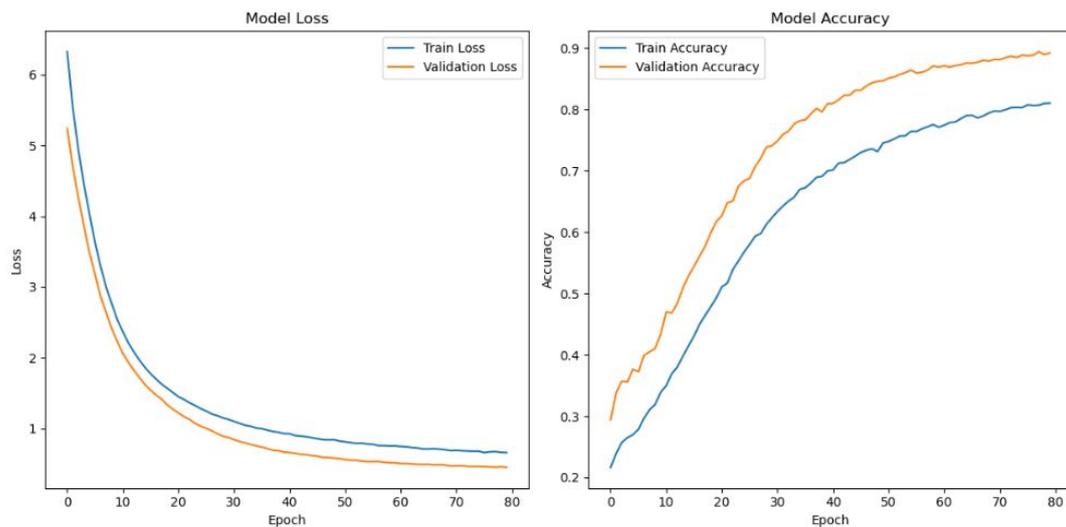


Figura 5.2: Accuracy y loss.

El modelo alcanzó una precisión del 89% en el conjunto de prueba, lo que demuestra una alta capacidad para clasificar correctamente emociones a partir de señales EEG.

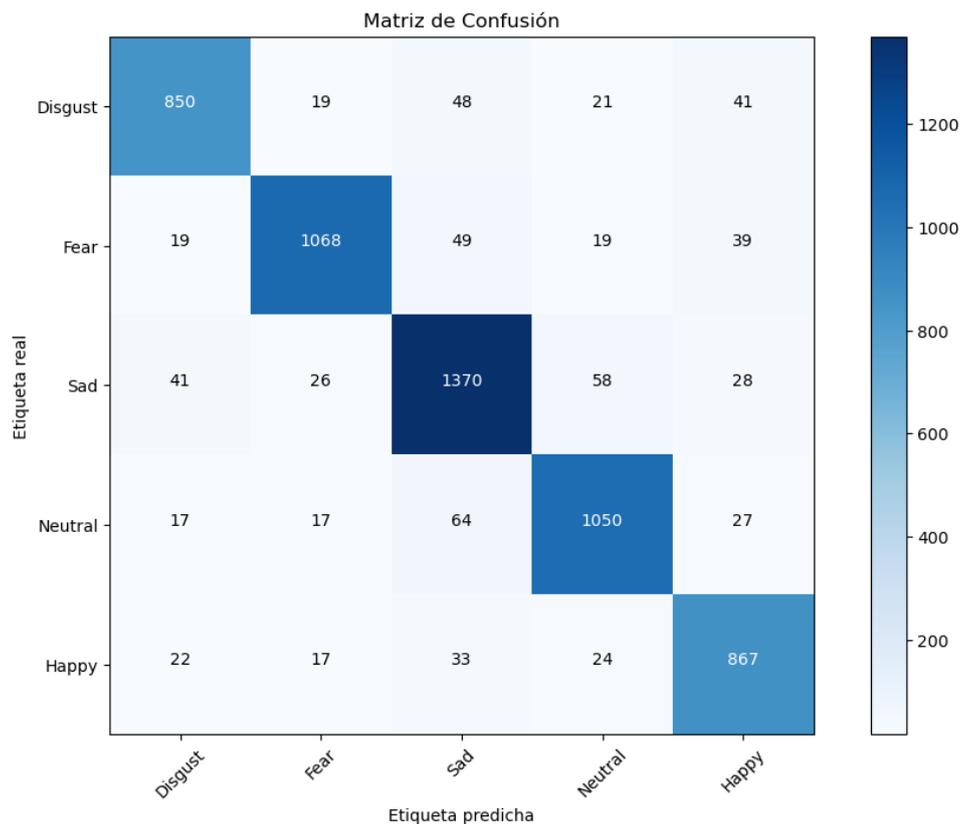


Figura 5.3: Matriz de confusión.

Clase	Precisión	Recall	F1-Score	Soporte
Disgust	0.90	0.87	0.88	979
Fear	0.93	0.89	0.91	1194
Sad	0.88	0.90	0.89	1523
Neutral	0.90	0.89	0.89	1175
Happy	0.87	0.90	0.88	963
Exactitud (Accuracy)	0.89 (5834 instancias)			
Media Macro	0.89	0.89	0.89	5834
Media Ponderada	0.89	0.89	0.89	5834

Tabla 5.3: Reporte de Clasificación para el modelo CNN

Observando los resultados de la matriz de confusión y de las métricas de clasificación podemos ver que el modelo clasifica correctamente la mayoría de las instancias en las respectivas categorías emocionales, con un buen rendimiento en todas las clases.

5.2 Modelo LSTM

En la clasificación de emociones a partir de EEG, uno de los enfoques que se implementó fue el uso de redes neuronales recurrentes. Las redes Long Short-Term Memory (LSTM) son especialmente adecuadas para procesar secuencias de datos, como las señales EEG, debido a su capacidad para capturar dependencias a largo plazo. Son numerosos estudios los que

determinan que las redes LSTM son el modelo más eficaz para predecir estados emocionales a partir de EEG [6].

El primer modelo desarrollado sigue una arquitectura básica de LSTM, cuyo objetivo principal era probar la viabilidad de esta red para la tarea de clasificación. La estructura del modelo se describe a continuación:

- **Capas LSTM:** La estructura incluye capas LSTM con 128 unidades que retornan secuencias, seguidas de capas de *Dropout* para mitigar el sobreajuste.
- **Capa de Salida:** La capa de salida es una capa densa con activación softmax, diseñada para clasificar las entradas en una de las cinco categorías emocionales

Layer Type	Output Shape	Parameters
Input	(10, 31)	-
LSTM	(10, 128)	128 units, return sequences = True
Dropout	(10, 128)	Dropout rate: 0.5
LSTM	(128)	128 units
Dropout	(128)	Dropout rate: 0.5
Dense (Output)	(5)	5 units, activation = Softmax

Tabla 5.4: Arquitectura del Modelo LSTM

Este modelo fue entrenado y los resultados mostraron la precisión comentada previamente, de un 0.88. Sin embargo, al analizar las gráficas de *accuracy* y *loss* se observó un problema significativo de *overfitting*. A pesar de que el modelo obtenía buenos resultados en el conjunto de entrenamiento, su rendimiento disminuye en el conjunto de validación.

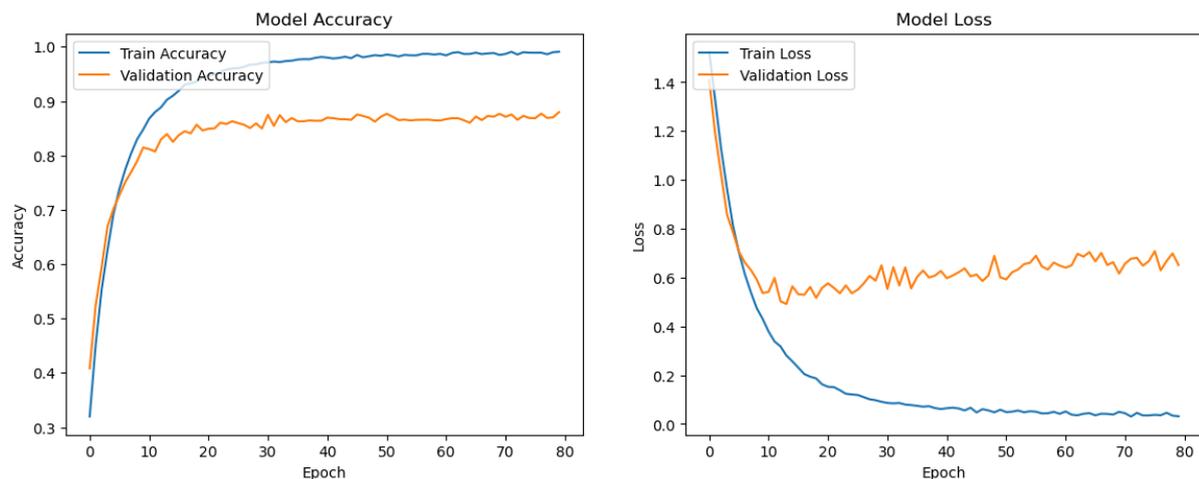


Figura 5.4: Gráficas de precisión (*accuracy*) y pérdida (*loss*) del modelo LSTM básico durante el entrenamiento.

Para abordar los problemas observados en el primer modelo, se llevaron a cabo diversas modificaciones con el objetivo de reducir el *overfitting* y mejorar la capacidad de generalización del modelo. La arquitectura mejorada incorporó varias técnicas como normalización por lotes (*Batch Normalization*), regularizador *L2* y una mayor tasa de *Dropout*.

- **Reducción de unidades LSTM:** Se redujo el número de unidades LSTM a 64 para simplificar el modelo y reducir la capacidad de sobreajuste.
- **Regularización L2:** Se incorpora regularización L2 en las capas LSTM.
- **Normalización por lotes:** Se introduce normalización por lotes después de cada capa LSTM para estabilizar el aprendizaje y mejorar la eficiencia.
- **Incremento de la tasa de Dropout:** Se incrementa la tasa de *Dropout* a 0.6 para ofrecer mayor protección contra el sobreajuste.
- **Ajuste de Learning Rate y aplicación de EarlyStopping:** Se implementó una tasa de aprendizaje más baja y la técnica de *Early Stopping*, para detener el entrenamiento cuando el rendimiento en el conjunto de validación dejaba de mejorar, evitando así el sobreajuste.

Layer Type	Output Shape	Parameters
Input	(10, 31)	-
LSTM	(10, 64)	64 units, return sequences = True, L2 regularization = 0.01
BatchNormalization	(10, 64)	-
Dropout	(10, 64)	Dropout rate: 0.6
LSTM	(64)	64 units, L2 regularization = 0.01
BatchNormalization	(64)	-
Dropout	(64)	Dropout rate: 0.6
Dense (Output)	(5)	5 units, activation = Softmax

Tabla 5.5: Modelo LSTM con Modificaciones

Este modelo logró solucionar en gran medida el problema de *overfitting*, como se puede observar en las gráficas de *accuracy* y *loss*. Sin embargo, esta solución vino acompañada de una ligera disminución en la precisión del modelo, que ahora se situaba por debajo del 0.87. Aunque el primer modelo era técnicamente más preciso, su utilidad práctica estaba limitada por su incapacidad para generalizar a nuevos datos.

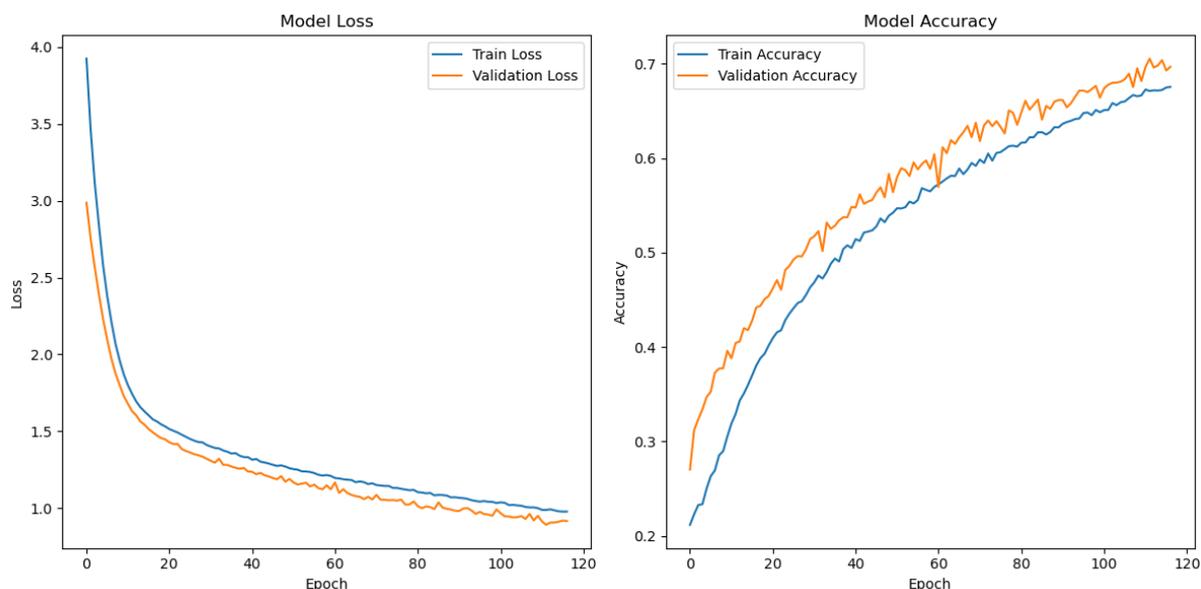


Figura 5.5: Gráficas de precisión (*accuracy*) y pérdida (*loss*) del modelo LSTM mejorado durante el entrenamiento.

Dado que la mejora en la precisión del modelo era un objetivo clave, se exploraron dos estrategias adicionales basadas en modelos avanzados:

Primera Estrategia: LSTM combinado con CNN. Esta estrategia intenta aprovechar las fortalezas de dos tipos de redes neuronales para mejorar la clasificación de emociones a partir de señales EEG: las redes LSTM y las redes convolucionales (CNN). Mientras que las LSTM son excelentes para capturar dependencias temporales en series de tiempo, las CNN son eficaces en la extracción de características espaciales, lo que es crucial para interpretar señales complejas como las EEG.

Segunda Estrategia: LSTM Bidireccional. Para mejorar la capacidad del modelo inicial de procesar secuencias temporales y capturar dependencias tanto de datos previos como futuros, se implementó un modelo LSTM Bidireccional. Este enfoque permite que el modelo acceda a información de contexto en ambas direcciones a lo largo de la secuencia temporal. En cualquier punto de los datos EEG las señales anteriores y posteriores pueden contener información relevante para la clasificación precisa de emociones con respecto a ese punto.

5.2.1. LSTM+CNN

En el desarrollo del modelo LSTM+CNN para el reconocimiento de emociones a partir de señales EEG, seguimos un enfoque híbrido que integra capacidades convolucionales y recurrentes. Similar al estudio realizado por Qazi et al. (2022), el modelo procesa inicialmente las señales EEG a través de una serie de capas convolucionales. Esto permite la extracción de características espaciales relevantes antes de analizar las dependencias temporales mediante las capas LSTM. Esta estrategia ha demostrado ser efectiva en la mejora de la precisión del reconocimiento de emociones.[30]

- **Capas CNN:** Comienza con una capa de entrada que recibe los datos EEG, seguida de varias capas convolucionales que incluyen normalización por lotes y *pooling* para reducir la dimensionalidad y aumentar la robustez del modelo.
- **Capas LSTM:** Después de las capas convolucionales, los datos procesados se utilizan en capas LSTM que pueden modelar dependencias a largo plazo, crucial para entender secuencias temporales en datos emocionales.

Model Part	Layer Type	Output Shape	Parameters
CNN	Input	(10, 31, 1)	-
	Conv2D	(10, 31, 32)	32 filters, 3×3 , ReLU, same padding
	BatchNormalization	(10, 31, 32)	-
	MaxPooling2D	(5, 16, 32)	Pool size: 2×2 , same padding
	Dropout	(5, 16, 32)	Dropout rate: 0.25
	Conv2D	(5, 16, 64)	64 filters, 3×3 , ReLU, same padding
	BatchNormalization	(5, 16, 64)	-
	MaxPooling2D	(3, 8, 64)	Pool size: 2×2 , same padding
	Dropout	(3, 8, 64)	Dropout rate: 0.25
	Conv2D	(3, 8, 128)	128 filters, 3×3 , ReLU, same padding
	BatchNormalization	(3, 8, 128)	-
	MaxPooling2D	(2, 4, 128)	Pool size: 2×2 , same padding
	Dropout	(2, 4, 128)	Dropout rate: 0.25
	Flatten	(1024)	-
LSTM	LSTM	(128)	128 units, return sequences, L2 regularization
	Dropout	(128)	Dropout rate: 0.6
	LSTM	(64)	64 units, L2 regularization
	Dropout	(64)	Dropout rate: 0.6
	Dense	(5)	5 units, Softmax

Tabla 5.6: Arquitectura del Modelo LSTM+CNN

El modelo LSTM+CNN alcanzó una precisión global de 0.91, lo que representa una mejora respecto a las arquitecturas anteriores.

Clase	Precisión	Recall	F1-Score	Soporte
Disgust	0.89	0.89	0.89	979
Fear	0.91	0.93	0.92	1194
Sad	0.94	0.91	0.92	1523
Neutral	0.92	0.91	0.91	1175
Happy	0.88	0.91	0.90	963
Exactitud (Accuracy)	0.91 (5834 instancias)			
Media Macro	0.91	0.91	0.91	5834
Media Ponderada	0.91	0.91	0.91	5834

Tabla 5.7: Reporte de Clasificación para el modelo LSTM+CNN

Los gráficos de precisión y pérdida durante el entrenamiento muestran cómo el modelo ha aprendido efectivamente a clasificar las emociones con una precisión alta y un sobreajuste mínimo.

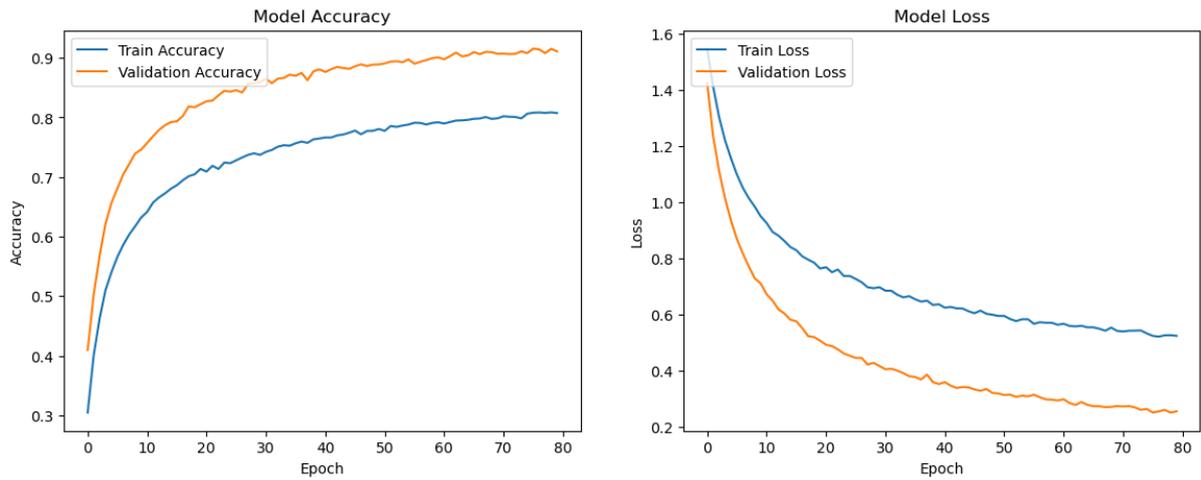


Figura 5.6: Gráficas de precisión (accuracy) y pérdida (loss) del modelo LSTM+CNN durante el entrenamiento.

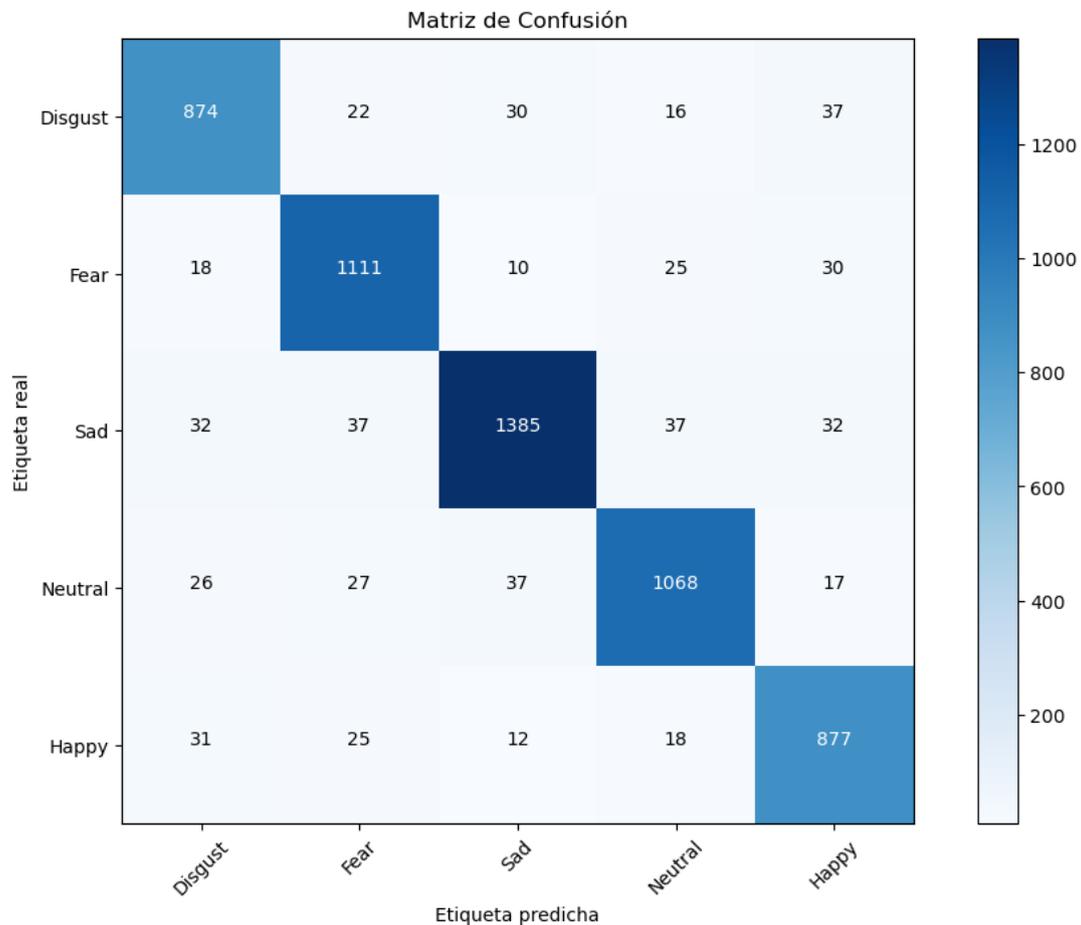


Figura 5.7: Matriz de confusión del modelo LSTM+CNN.

Estos gráficos y la matriz de confusión ofrecen una visión detallada del rendimiento del modelo y resaltan su capacidad para generalizar bien a nuevos datos, lo que es esencial para aplicaciones prácticas en entornos reales donde los datos pueden variar considerablemente. Combinar CNN y LSTM demuestra ser una estrategia eficaz para el problema de clasificación

de emociones utilizando datos EEG. Este enfoque captura la complejidad presente en los datos emocionales.

5.2.2. LSTM Bidireccional

Para mejorar la capacidad del modelo inicial de procesar secuencias temporales y capturar dependencias tanto del pasado como del futuro, se implementó el siguiente LSTM bidireccional. La arquitectura específica del modelo fue diseñada para maximizar la captura de estas dependencias temporales bidireccionales, una técnica que ha demostrado ser efectiva en estudios recientes como el realizado por *Huang et al. (2023)*. Este estudio propone un modelo combinado de Bi-LSTM, destacando la eficacia de los LSTM bidireccionales en la mejora de la precisión y la relevancia de las características temporales en el reconocimiento de emociones a partir de EEG [31].

- **Capas LSTM Bidireccionales:** Utilizadas para procesar la entrada en ambas direcciones, permitiendo al modelo aprender de toda la información disponible en la secuencia.
- **Regularización y Normalización:** Se aplicó regularización L2 y *Dropout* en las capas LSTM para prevenir el sobreajuste, junto la normalización por lotes para mejorar la estabilidad del entrenamiento.
- **Capas Densas:** Una capa de salida densa con activación softmax clasifica las entradas en una de cinco categorías emocionales basadas en las características aprendidas por las capas LSTM.

Tipo de Capa	Forma de Salida	Parámetros
Input	(10, 31)	-
Bidirectional LSTM	(10, 128)	128 unidades, Regularización L2, Dropout 0.5
BatchNormalization	(10, 128)	-
Bidirectional LSTM	(10, 128)	128 unidades, Regularización L2, Dropout 0.5
BatchNormalization	(10, 128)	-
LSTM	(64)	64 unidades, Regularización L2, Dropout 0.4
BatchNormalization	(64)	-
Dense	(5)	5 unidades, Softmax

Tabla 5.8: Arquitectura del Modelo LSTM Bidireccional

El modelo fue entrenado utilizando una tasa de aprendizaje reducida y con la implementación de las técnicas de *EarlyStopping* y *ReduceLROnPlateau* para optimizar el entrenamiento. Los resultados obtenidos son los siguientes.

Como se observa en las métricas, el modelo logró una precisión del 95 % en la clasificación de las 5 emociones en el conjunto de validación.

En las figuras siguientes, se presentan las gráficas de pérdida y la precisión durante el entrenamiento y la matriz de confusión obtenida en la evaluación final del modelo.

Clase	Precisión	Recall	F1-Score	Soporte
Disgust	0.95	0.93	0.94	979
Fear	0.96	0.95	0.96	1194
Sad	0.95	0.96	0.95	1523
Neutral	0.95	0.95	0.95	1175
Happy	0.93	0.94	0.93	963
Exactitud (Accuracy)	0.95 (5834 instancias)			
Media Macro	0.95	0.95	0.95	5834
Media Ponderada	0.95	0.95	0.95	5834

Tabla 5.9: Reporte de Clasificación para el modelo LSTM Bidireccional

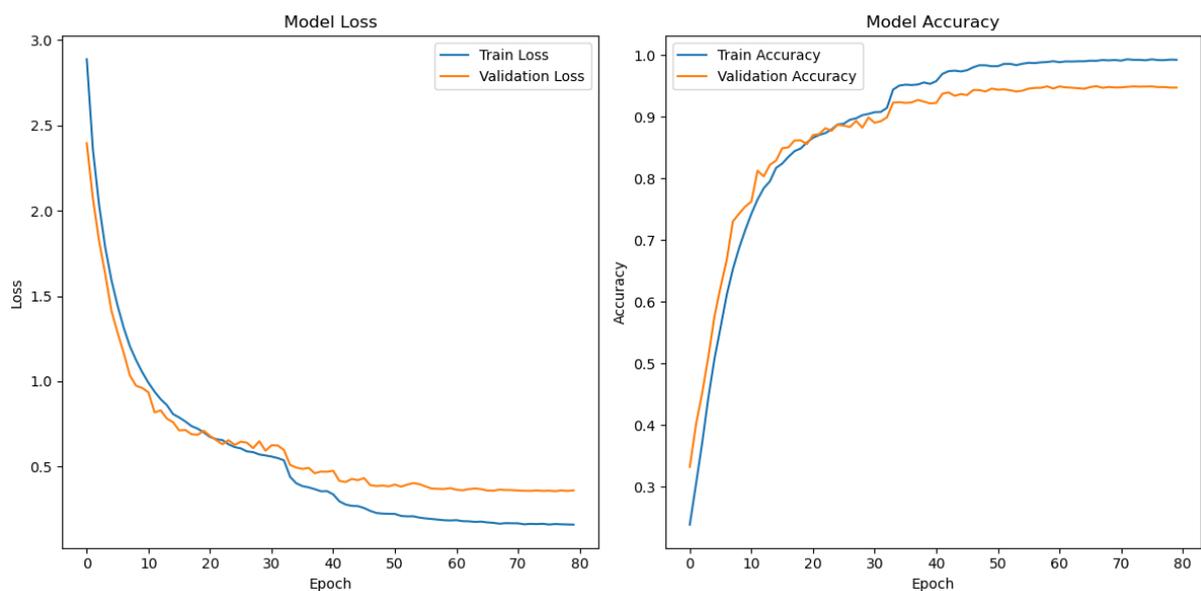


Figura 5.8: Gráficas de precisión (accuracy) y pérdida (loss) del modelo LSTM Bidireccional durante el entrenamiento.

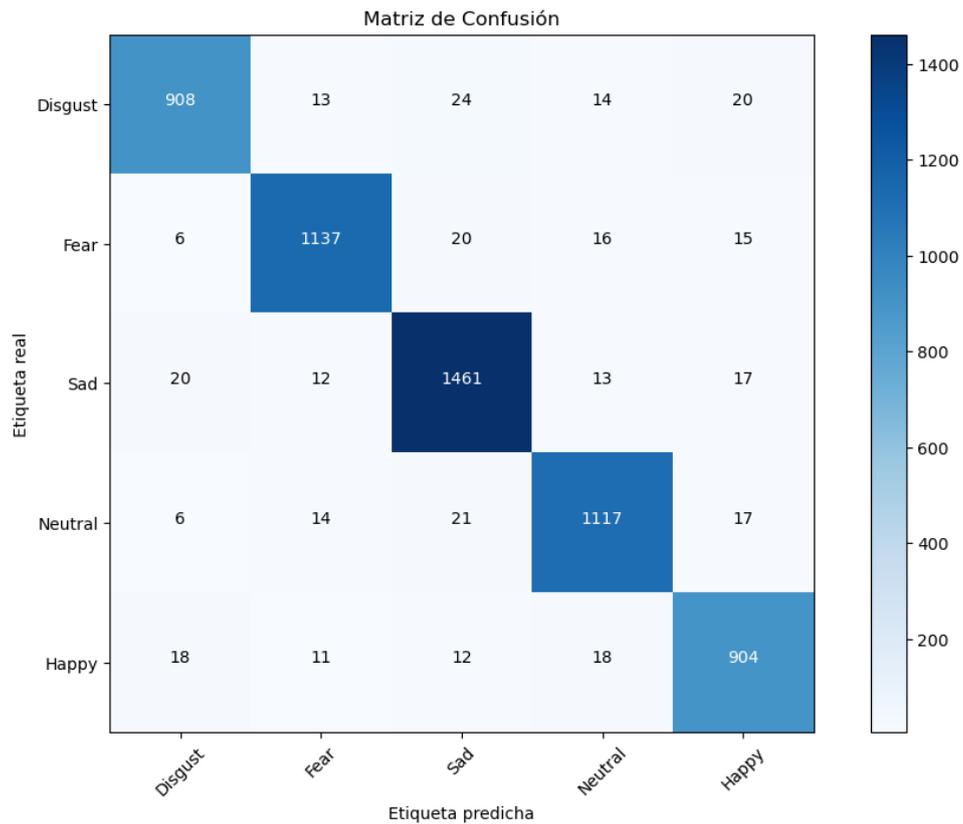


Figura 5.9: Matriz de confusión para el modelo LSTM Bidireccional en el conjunto de validación.

El rendimiento de este modelo representa una mejora significativa en comparación con los modelos anteriores, alcanzando una alta precisión y manteniendo un buen equilibrio entre las diferentes clases, lo que se refleja en la matriz de confusión y en las métricas de clasificación. Los resultados muestran cómo la incorporación de información temporal en ambas direcciones puede enriquecer significativamente la capacidad de un modelo para clasificar emociones a partir de señales EEG.

CAPÍTULO 6

Despliegue

En la presente sección, se trata el despliegue del modelo desarrollado para el reconocimiento de emociones a partir de datos EEG, empleando un enfoque experimental que replica la metodología utilizada en el dataset SEED-V. Este dataset ha sido la base para el entrenamiento de los modelos de clasificación a lo largo de este estudio, destacando su relevancia en la investigación de la interfaz cerebro-computadora orientada al análisis emocional.

El experimento diseñado para la validación implicó la participación de cinco individuos, quienes fueron expuestos a una serie de vídeos que inducían las cinco emociones tratadas anteriormente, felicidad, tristeza, neutralidad, miedo y asco. Durante la inducción emocional se recogieron los datos EEG utilizando un headset de bajo coste y precisión, el *OpenBCI Ultracortex Mark IV* configurado para obtener información de 16 canales.

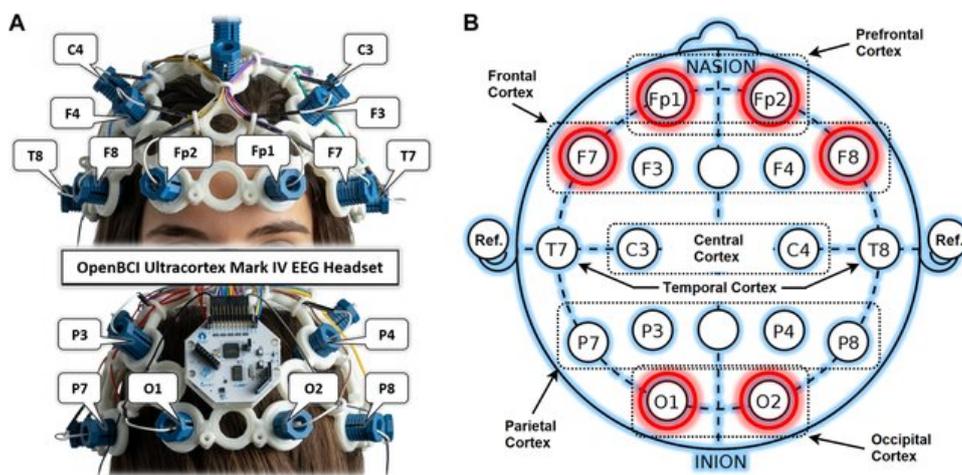


Figura 6.1: Headset Ultracortex Mark IV de 16 canales.

[32]

Posteriormente los datos recogidos fueron procesados y evaluados utilizando los algoritmos de procesamiento y modelos de clasificación desarrollados en este trabajo, con el fin de testar su eficacia en un entorno menos controlado y con señales de peor calidad, y comparar los resultados obtenidos previamente sobre el dataset SEED-V. Esta sección detalla el proceso experimental paso a paso, desde la preparación hasta la evaluación final.

6.1 Diseño del experimento

El experimento se diseñó para evaluar la respuesta emocional de los participantes mediante la exposición a una serie de vídeos que inducen distintas emociones. Cada participante visualizó cinco videos que representaban emociones de asco, miedo, tristeza, neutralidad y alegría, en ese orden específico. La secuencia de cada sesión incluyó una introducción breve seguida del vídeo correspondiente.

Para garantizar la relevancia de los datos recogidos para el estudio, se descartaron los primeros 15 a 30 segundos de cada introducción y final del video. Este procedimiento se realiza para evitar incluir datos registrados mientras el participante no estaba expuesto a ningún estímulo emocional. La frecuencia de muestreo durante la captura de los datos fue de 125Hz, muy inferior a la utilizada en los datos del SEED-V.



Figura 6.2: Línea temporal del experimento.



Figura 6.3: Realización del experimento.

6.2 Procesamiento de los datos

Como se ha visto ya en la evaluación de los modelos, el procesamiento de los datos EEG es una fase crucial para asegurar la precisión en la clasificación de emociones inducidas. El procedimiento para preparar los datos para el análisis ha sido el siguiente:

Inicialmente, los datos recogidos de cada participante se dividieron en cinco datasets separados, correspondientes a cada uno de los vídeos visualizados. Descartando así los segmentos de datos entre vídeos para los que las señales EEG recogidas no tienen relevancia. Esta división, al igual que se realizó con los datos del SEED-V permite tratar cada trial por separado, optimizando el procesamiento específico para la emoción inducida en cada segmento.

Para el procesamiento de la señal, se empleó el algoritmo previamente desarrollado y descrito en las secciones anteriores. Este algoritmo fue diseñado para trabajar con 62 canales. Dado que en este experimento se utilizó un headset de bajo coste con solo 16 canales, fue necesario realizar adaptaciones en la configuración del algoritmo para ajustarse al hardware. El resto del procesamiento se ha mantenido igual.

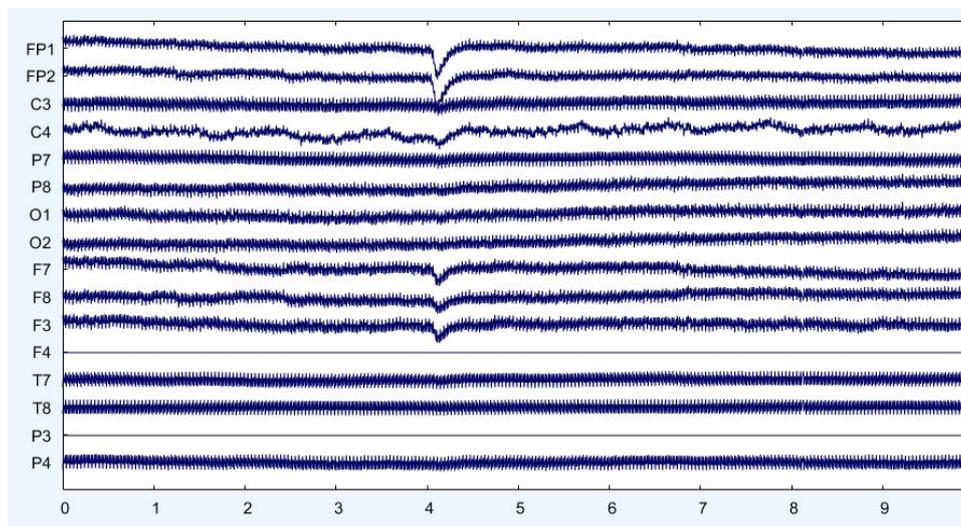


Figura 6.4: Ejemplo de señal recogida en el experimento.

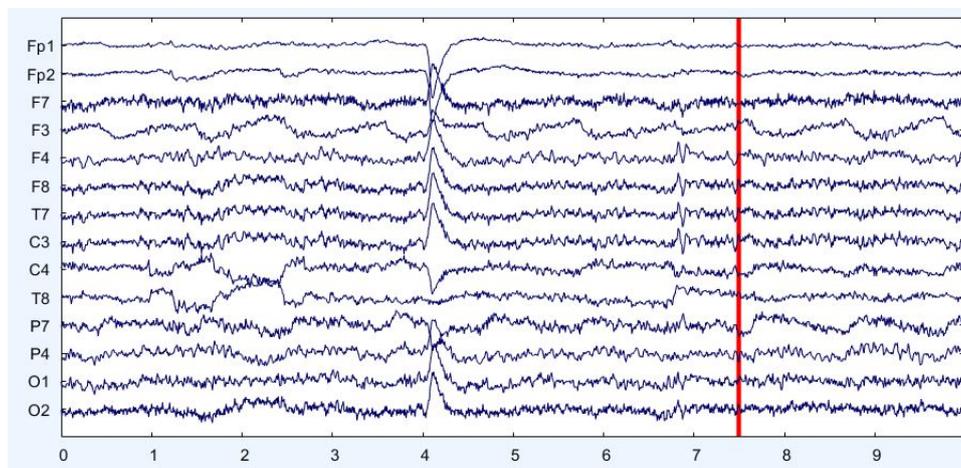


Figura 6.5: Misma señal tras el procesamiento.

En la primera imagen, las señales aparecen con una amplitud bastante uniforme y con trazos gruesos, lo cual puede indicar presencia de ruido de línea o artefactos eléctricos, que se aplican en todos los canales al mismo tiempo. Este tipo de ruido suele ser constante y puede enmascarar las verdaderas señales cerebrales que se desean estudiar. La Figura 6.4, muestra una señal después de un procesamiento que ha reducido este ruido, con señales que revelan más claramente las variaciones naturales de la actividad cerebral.

Siguiendo con la metodología empleada con los datos de entrenamiento del SEED-V, se extrajeron características basadas en la diferencia de entropía de las señales procesadas.

Paralelamente, los datos utilizados anteriormente en la fase de entrenamiento, que habían sido procesados considerando 62 canales, fueron procesados de nuevo con las modificaciones del algoritmo, utilizando ahora solamente los 16 canales disponibles en el nuevo experimento.

6.3 Análisis de resultados

Al aplicar los modelos de clasificación previamente entrenados con el dataset SEED-V, en el nuevo conjunto de datos de prueba, los resultados han demostrado una notable disminución en la precisión en comparación a los obtenidos en las pruebas anteriores, donde se alcanzaron resultados alrededor del 90 %, a diferencia de la precisión del 30 % alcanzada con los nuevos datos. Debido a esta discrepancia en el rendimiento, se ha tratado de investigar los posibles factores que podrían estar influyendo en la eficacia de los modelos sobre estos datos.

6.3.1. Factores que Influyen en los Resultados

1. **Calidad de la Señal y Experiencia en la Captura:** La calidad de la señal EEG es un factor determinante en la eficacia de cualquier modelo de clasificación basado en EEG. En este proyecto, la captura de datos fue realizada por primera vez, sin la experiencia y la precisión de los setups utilizados en la creación del dataset SEED-V. Este hecho podría haber introducido un nivel más alto de ruido y artefactos en las señales capturadas, afectando directamente la calidad de los datos y en consecuencia, la precisión de la clasificación. Además, se utilizó un casco con especificaciones muy inferiores a las del equipo usado para el SEEDV, lo cual podría justificar la reducción en la calidad de las señales.
2. **Reducción en la Cantidad de Canales:** El modelo originalmente diseñado para 62 canales tuvo que ser adaptado a un sistema de solo 16 canales, limitando significativamente la cantidad de información disponible para el análisis. Esta reducción de canales implica una pérdida de datos espaciales que podrían ser cruciales para identificar patrones más complejos asociados con diferentes emociones.
3. **Volumen y Calidad de los Datos:** El volumen de datos disponible también jugó un papel crucial. El conjunto de datos recogidos fue considerablemente menor en comparación con el SEED-V, y muchos segmentos tuvieron que ser descartados debido a problemas en la recogida de los mismos. Esto no solo redujo la cantidad de datos disponibles para el entrenamiento y las pruebas sino que también pudo haber introducido un sesgo en el conjunto de datos que quedó para el análisis.
4. **Frecuencia de Muestreo:** La frecuencia de muestreo del equipo utilizado también fue significativamente inferior a la del SEED-V. Esto afecta la capacidad del modelo para captar cambios sutiles en la actividad cerebral que podrían ser críticos para el reconocimiento de emociones. Una frecuencia de muestreo más baja puede perder detalles importantes, lo que disminuye la precisión de los modelos de clasificación al limitar el rango de frecuencias disponibles para el análisis. En el caso de este proyecto, esta limitación pudo

haber afectado la capacidad de los modelos para detectar con precisión ciertos patrones neuronales relacionados con las emociones.

5. **Entorno de Experimentación no Suficientemente Aislado:** El entorno en el que se realizaron los experimentos no estaba completamente controlado o aislado de fuentes externas de interferencia, como el ruido ambiental o la actividad eléctrica de otros dispositivos cercanos. Este tipo de interferencias puede generar artefactos en las señales EEG, lo que impacta negativamente en la calidad de los datos capturados. Un entorno menos controlado puede introducir variabilidad no deseada, dificultando la identificación de patrones consistentes en las señales y reduciendo la eficacia de los modelos de clasificación.

6.3.2. Conclusiones y Propuestas de Mejora para el Experimento

Este experimento ha permitido aplicar los modelos de clasificación de emociones desarrollados con el dataset SEED-V en un nuevo contexto experimental. Con la recogida de datos EEG de cinco participantes, se ha logrado replicar parcialmente las condiciones del SEED-v, y obteniendo resultados que, si bien no alcanzaron la precisión original esperada, ofrecen una serie de conclusiones interesantes para futuros estudios en este campo.

- **Relevancia de la calidad de los datos:** Uno de los aspectos más evidentes, pero igualmente críticos que ha sido confirmado con este estudio es la importancia de la calidad de los datos en los estudios de clasificación emocional mediante EEG. La presencia de ruido, artefactos externos o el material usado en la recogida de datos afecta considerablemente el rendimiento de los modelos, lo que refuerza la idea de que, por muy avanzado que sea el preprocesamiento, su capacidad para corregir problemas en los datos es limitada.
- **Número de electrodos utilizado:** Las pruebas en este estudio sobre el dataset del SEED-V con 16 canales en lugar de 62, demuestran que la calidad de la clasificación se ve directamente afectada por el número de canales utilizado, ya que la precisión disminuye considerablemente. Por tanto, concluimos con que 16 canales pueden ser insuficientes para la predicción.
- **Distribución de los electrodos:** Una de las pruebas realizadas durante el experimento fue utilizar únicamente los canales frontales, debido a que investigaciones previas han demostrado que el lóbulo frontal está altamente implicado en el procesamiento emocional. Para realizar esta prueba se repitió el preprocesamiento y la extracción de características en el conjunto del SEED-V solo para estos 16 canales específicamente. Al probar los modelos de clasificación en el conjunto de entrenamiento con los canales frontales, los resultados eran algo mejores que cuando se utilizaban los 16 canales distribuidos de manera uniforme. Esto sugiere que concentrar los canales en áreas específicas como el lóbulo frontal que forma parte del sistema límbico implicado en la elicitación de emociones, puede compensar en parte la reducción del número total de canales.

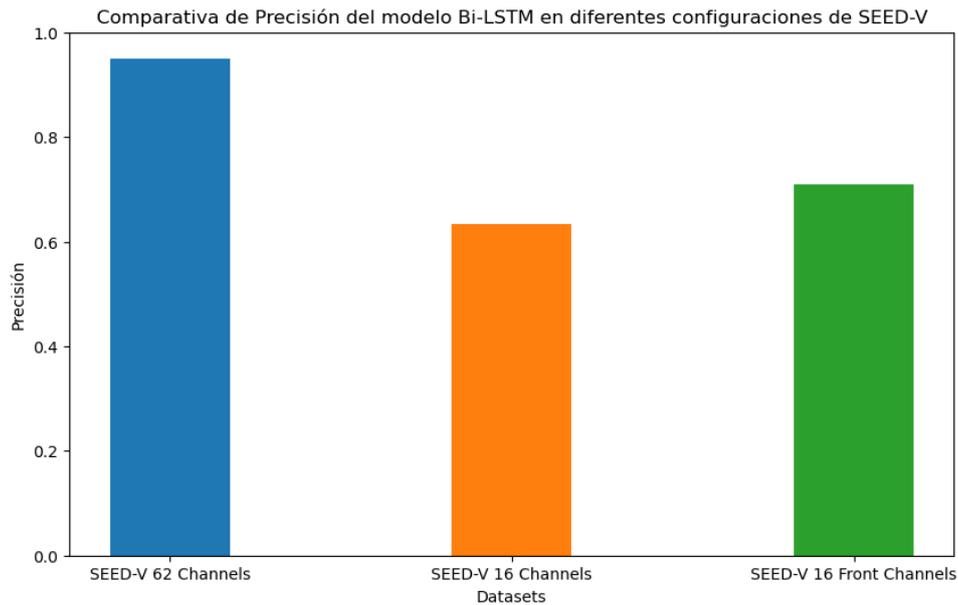


Figura 6.6: Comparativa del número y localización de los canales.

Para mejorar la precisión y eficacia en experimentos futuros se sugiere en primer lugar optimizar la calidad de los datos EEG, tratando de minimizar el ruido y artefactos que puedan generarse durante el experimento. Utilizar el mayor número de canales posible o concentrar los electrodos en zonas clave del cerebro, como los lóbulos frontales parece ser una estrategia efectiva para mejorar la precisión del análisis emocional. También el emplear un equipo de nivel médico es de gran importancia para la recolección de datos EEG adecuados para la clasificación emocional. Finalmente, sería esencial aumentar el tamaño del conjunto de datos, mediante la inclusión de más participantes o realizando múltiples sesiones con los mismos individuos, esto ayudaría a obtener un mayor volumen de datos representativos y mejorar la capacidad de generalización de los modelos.

CAPÍTULO 7

Conclusiones

Con este Trabajo de Fin de Grado se ha tratado de contribuir al campo de reconocimiento de emociones a partir de señales de electroencefalografía. A lo largo del proyecto se han alcanzado importantes logros, especialmente en lo que respecta al preprocesamiento de señales y al desarrollo de modelos avanzados de aprendizaje automático.

Uno de los mayores logros del proyecto ha sido la implementación de un algoritmo de preprocesamiento de señales EEG que ha demostrado ser crucial para mejorar la calidad de los datos utilizados en los modelos de clasificación. Este preprocesamiento permitió eliminar artefactos, filtrar ruido y optimizar los canales de manera eficiente, lo que tuvo un impacto directo en el rendimiento de los modelos de aprendizaje profundo. Comparado con datos que no fueron preprocesados, los resultados obtenidos mostraron un incremento significativo en la precisión de los modelos. Este avance subraya la relevancia del preprocesamiento en el análisis de señales EEG y cómo su correcta aplicación puede maximizar la eficacia de los algoritmos empleados en la clasificación emocional.

También se logró desarrollar una metodología robusta para la extracción de características relevantes de las señales EEG. La utilización de estas técnicas permitió obtener una representación detallada de las señales, adecuada para la clasificación de emociones. Esta extracción de características tiene un papel crucial en la eficacia de los modelos, resultando en altas tasas de precisión.

Los modelos de aprendizaje profundo desarrollados durante el estudio lograron tasas de precisión muy elevadas cuando se aplicaron a los datos preprocesados. Los resultados con los datos proporcionados por el BCMI validan la metodología seguida, ya que estos modelos fueron capaces de identificar emociones con gran precisión, lo que constituye un éxito clave en el proyecto.

Sin embargo, se presentaron ciertas limitaciones a la hora de clasificar datos externos no utilizados en el entrenamiento. A pesar de los avances logrados con los datos internos, el sistema mostró dificultades al enfrentarse a datos externos, principalmente debido a la calidad subóptima de las señales recolectadas, que contenían una mayor cantidad de ruido y artefactos. Este problema afectó la capacidad de generalización del modelo, subrayando la importancia crítica de la calidad de los datos en todo el proceso de clasificación. Aunque este objetivo no se alcanzó plenamente, la conclusión más relevante es que los modelos son capaces de funcionar de manera excelente si los datos utilizados son de alta calidad, lo que refuerza la necesidad de mejorar los procedimientos de adquisición de datos en estudios futuros.

En resumen, el proyecto ha logrado avances notables en la implementación de un sistema eficiente para el procesamiento y análisis de señales EEG, y ha demostrado que, con datos de alta calidad, es posible obtener clasificaciones de emociones muy precisas mediante modelos de aprendizaje profundo. Las técnicas y modelos desarrollados proporcionan una base sólida

para investigaciones futuras en este campo, con potencial para mejorar sistemas de reconocimiento emocional en contextos como la salud mental, la interacción humano-computadora y otras aplicaciones tecnológicas.

7.1 Legado

Este Trabajo de Fin de Grado deja un legado significativo tanto en términos académicos como prácticos, contribuyendo al campo del reconocimiento de emociones a partir de señales EEG. A continuación, se detallan las principales contribuciones y cómo éstas pueden ser aprovechadas en futuros desarrollos.

El principal aporte del proyecto es la implementación de un algoritmo de preprocesamiento avanzado de señales EEG, junto con un sistema eficiente para la extracción de características y clasificación de emociones mediante modelos de aprendizaje profundo. Esta metodología no solo proporciona una base sólida para estudios futuros, sino que también puede ser replicada y extendida por otros investigadores y profesionales interesados en el análisis de señales EEG y el reconocimiento de emociones. Para facilitar el acceso y la reproducibilidad de los resultados obtenidos, se ha dispuesto el código fuente y los conjuntos de datos utilizados en repositorios accesibles públicamente:

- Código del proyecto: [GitHub - TFG_FINAL](#)
- Datos procesados: [TFG Datasets](#)

Estos recursos permiten que cualquiera pueda acceder al código, los datos y la documentación del proyecto, facilitando la reproducción de los análisis realizados. A nivel práctico, el trabajo realizado tiene un impacto a corto y medio plazo en áreas relacionadas con la salud mental y la interacción humano-computadora, donde el reconocimiento emocional es fundamental. Los resultados y metodologías desarrollados podrían ser aplicados para mejorar interfaces afectivas, sistemas de monitoreo de emociones en pacientes o incluso en aplicaciones comerciales como neuromarketing o entretenimiento.

A largo plazo, el legado del proyecto reside en haber establecido una metodología sólida para el procesamiento de señales EEG y la clasificación emocional, proporcionando una base para futuras investigaciones en el campo de la neurociencia afectiva. A partir de los recursos proporcionados, este proyecto ofrece la posibilidad de seguir avanzando esta línea de investigación y mejorando los sistemas actuales.

7.2 Relación con los estudios cursados

1. **Estructuras de Datos:** Esta asignatura me proporcionó el conocimiento esencial sobre la organización y manipulación eficiente de datos complejos, una habilidad clave para el procesamiento de las señales EEG y la implementación de estructuras necesarias para la manipulación de grandes volúmenes de datos durante la clasificación de emociones.
2. **Modelos Descriptivos y Predictivos I y II:** Las herramientas estadísticas y de aprendizaje automático adquiridas en estas asignaturas fueron cruciales para el análisis y la interpretación de los datos EEG multivariantes. Las técnicas aprendidas permitieron desarrollar modelos predictivos robustos y realizar análisis críticos sobre la efectividad de estos modelos, fundamentales para mi proyecto.

3. **Proyecto I, II y III:** La experiencia obtenida en estas asignaturas fue crucial para aprender a gestionar y organizar proyectos en todas sus etapas. La capacidad de planificar eficientemente, desde la concepción hasta la ejecución y evaluación final, fue directamente aplicable al desarrollo de mi TFG. Esta formación me ha permitido coordinar diversas fases del estudio, asegurando una ejecución fluida y sistemática que es esencial en cualquier proyecto.
4. **Evaluación, Despliegue y Monitorización de Modelos:** Esta asignatura fue de gran utilidad para evaluar críticamente el rendimiento de los modelos, desplegar soluciones escalables y monitorear la eficacia de los sistemas de inteligencia artificial, aspectos todos implementados en la fase final de mi proyecto.
5. **Modelado y Simulación Continuos:** El estudio sobre series de Fourier adquirido en esta asignatura fue esencial para el análisis y procesamiento de las señales EEG. Este conocimiento permitió una manipulación más precisa de las señales mediante la implementación de herramientas como filtros, las cuales fueron cruciales para el desarrollo del proyecto. El conocimiento sobre la herramienta Matlab adquirido en esta asignatura también ha sido de gran utilidad en el proyecto.
6. **Marco Profesional, Legal y Deontológico:** He podido aplicar los conocimientos adquiridos en la asignatura de marco legal para tratar de manera efectiva los desafíos éticos y normativos. Me ha permitido gestionar cuestiones críticas de privacidad y consentimiento informado, aspectos fundamentales al utilizar datos biométricos.
7. **Biomedical Data Science:** Esta asignatura me proporcionó una perspectiva específica sobre cómo manejar, analizar e interpretar datos biomédicos, directamente aplicable al trabajo con datos EEG, y esencial para comprender el contexto médico y biológico detrás de las emociones humanas.
8. **Cursos de Deep Learning y Data Science:** Estas asignaturas cursadas durante mi erasmus en la Universidad Técnico de Lisboa, ampliaron aún más mi conocimiento en técnicas avanzadas de aprendizaje automático, incluyendo redes neuronales profundas, que fueron aplicadas para mejorar la precisión y la capacidad predictiva de los modelos de clasificación de emociones en mi TFG.

En conclusión, la integración de los conocimientos y habilidades adquiridos a lo largo de mi formación académica han sido esenciales para abordar con éxito los retos técnicos y teóricos presentados en mi Trabajo Final de Grado. La educación recibida no solo me ha preparado para aplicar estas competencias de manera efectiva, sino que también ha establecido una sólida base para futuras investigaciones y desarrollos profesionales en el campo de la ciencia de datos y el procesamiento de señales biomédicas.

Bibliografía

- [1] Hooi Nee Oon, A. Saidatul, and Z. Ibrahim. Analysis on non-linear features of electroencephalogram (eeg) signal for neuromarketing application. In *2018 International Conference on Computational Approach in Smart Systems Design and Applications (ICASSDA)*, pages 1–8. IEEE, 2018.
- [2] Johns Hopkins Medicine. Anatomy of the brain, 2021. <https://www.hopkinsmedicine.org/health/conditions-and-diseases/anatomy-of-the-brain>.
- [3] Robert Plutchik. The nature of emotions. *American Scientist*, 89:344–350, 2001.
- [4] James A. Russell. A circumplex model of affect. *Journal of Personality and Social Psychology*, 39(6):1161–1178, 1980.
- [5] Suguru Kanoga and Yasue Mitsukura. Review of artifact rejection methods for electroencephalographic systems. *Journal of Biomedical Science and Engineering*, 10(2), 2017.
- [6] Hoda Shrara, Hadi Ammar, Mohamad Nasserredine, Jamal Charara, and Fatima Sbeity. An eeg-based emotion recognition study using machine learning and deep learning. In *2023 Seventh International Conference on Advances in Biomedical Engineering (ICABME)*, pages 125–129, Oct 2023.
- [7] Yanjing Mao, Liang Song, and Xinhua Zeng. Emotion classification from short-term EEG signals in deep learning. In *2021 3rd International Symposium on Smart and Healthy Cities (ISHC)*, pages 168–173. IEEE, 2021.
- [8] Rosalind W. Picard. *Affective computing*. MIT press, 1997.
- [9] David Moher, Alessandro Liberati, Jennifer Tetzlaff, Douglas G. Altman, and The PRISMA Group. Preferred reporting items for systematic reviews and meta-analyses: The prisma statement. *PLOS Medicine*, 6(7):e1000097, 2009.
- [10] IEEE. Ieee xplora digital library. Database for accessing technical documents in engineering, computer science, and electronics, 2024. Available online: <https://ieeexplore.ieee.org/>.
- [11] Clarivate Analytics. Web of science. Research database for scholarly publications and citation analysis across multiple disciplines, 2024. Available online: <https://www.webofscience.com/>.
- [12] Chunmei Qing, Rui Qiao, Xiangmin Xu, and Yongqiang Cheng. Interpretable emotion recognition using eeg signals. *IEEE Access*, 7:94160–94170, 2019.
- [13] Rafael A Calvo and Sidney D’Mello. Affect detection: An interdisciplinary review of models, methods, and their applications. *IEEE Transactions on Affective Computing*, 1(1):18–37, 2010.

- [14] Nazmi Sofian Suhaimi, James Mountstephens, and Jason Teo. Eeg-based emotion recognition: A state-of-the-art review of current trends and opportunities. *Computational Intelligence and Neuroscience*, 2020:1–19, 2020.
- [15] Xiang Li, Yazhou Zhang, Prayag Tiwari, Dawei Song, Bin Hu, Meihong Yang, Zhigang Zhao, Neeraj Kumar, and Pekka Marttinen. Eeg-based emotion recognition: A tutorial and review. *ACM Computing Surveys*, 1(1):1–34, 2022.
- [16] Yi Liu, Yixuan Su, and Yu Liu. Emotion recognition from multi-channel eeg data through convolutional recurrent neural network. In *Proceedings of the International Conference on Computational Intelligence and Neuroscience (CIN)*. IEEE, 2022.
- [17] Xiang Li, Dawei Song, Peng Zhang, Guangliang Yu, Yuexian Hou, and Bin Hu. Emotion recognition from multi-channel eeg data through convolutional recurrent neural network. In *2016 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, pages 352–359, 2016.
- [18] Shuaiqi Liu, Xu Wang, Ling Zhao, Bing Li, Weiming Hu, Jie Yu, and Yu-Dong Zhang. 3dcann: A spatio-temporal convolution attention neural network for eeg emotion recognition. *IEEE Journal of Biomedical and Health Informatics*, 26(11):5321–5331, Nov 2022.
- [19] Yuxuan Zhao, Jin Yang, Jinlong Lin, Dunshan Yu, and Xixin Cao. 3d convolutional neural network for emotion recognition based on eeg signals. In *Proceedings of the International Conference on Human-Machine Interaction*. IEEE, 2020.
- [20] Juan Manuel Mayor-Torres, Mirco Ravanelli, Sara E. Medina-DeVilliers, Matthew D. Lerner, and Giuseppe Riccardi. Interpretable sincnet-based deep learning for emotion recognition from eeg brain activity. In *2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, pages 412–415. IEEE, 2021.
- [21] Conectiva. Efectos farmacológicos visibles en el eeg. <https://conectiva.eu/salud-mental/efectos-farmacologicos-visibles-en-el-eeg/>. Accedido: 3 de septiembre de 2024.
- [22] Wang F. Cao C. Wu R. Wang X. Gu, S. and A. Kemp. Neurotransmitters in the central nervous system and their implication in learning and memory in the hippocampus. *Frontiers in Psychology*, 10:21, 2019.
- [23] Wei Liu, Jie-Lin Qiu, Wei-Long Zheng, and Bao-Liang Lu. Comparing recognition performance and robustness of multimodal deep learning models for multimodal emotion recognition. *IEEE Transactions on Cognitive and Developmental Systems*, 13(2):354–367, 2021.
- [24] Alexandre Gramfort, Martin Luessi, Eric Larson, Denis Engemann, Daniel Strohmeier, Christian Brodbeck, Roman Goj, Mainak Jas, Teon Brooks, Lauri Parkkonen, and Matti Hämäläinen. *MEG and EEG data analysis with MNE-Python*. Zenodo, 2013. <https://mne.tools/stable/index.html>.
- [25] Martín Abadi, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, Greg S. Corrado, Andy Davis, Jeffrey Dean, Matthieu Devin, Sanjay Ghemawat, Ian Goodfellow, Andrew Harp, Geoffrey Irving, Michael Isard, Yangqing Jia, Rafal Jozefowicz, Lukasz Kaiser, Manjunath Kudlur, Josh Levenberg, Dandelion Mané, Rajat Monga, Sherry Moore, Derek Murray, Chris Olah, Mike Schuster, Jonathon Shlens, Benoit Steiner, Ilya Sutskever, Kunal Talwar, Paul Tucker, Vincent Vanhoucke, Vijay Vasudevan, Fernanda Viégas, Oriol Vinyals, Pete Warden, Martin Wattenberg, Martin Wicke, Yuan Yu, and Xiaoqiang Zheng. TensorFlow: Large-scale machine learning on heterogeneous systems. <https://www.tensorflow.org/>, 2015.

- [26] Adam Paszke, Sam Gross, Francisco Massa, Adam Lerer, James Bradbury, Gregory Chanan, Trevor Killeen, Zeming Lin, Natalia Gimelshein, Luca Antiga, Alban Desmaison, Andreas Kopf, Edward Yang, Zachary DeVito, Martin Raison, Alykhan Tejani, Sasank Chilamkurthy, Benoit Steiner, Lu Fang, Junjie Bai, and Soumith Chintala. Pytorch: An imperative style, high-performance deep learning library, 2019. <https://pytorch.org/>.
- [27] Arnaud Delorme and Scott Makeig. Eeglab: an open source toolbox for analysis of single-trial eeg dynamics including independent component analysis. *Journal of Neuroscience Methods*, 134:9–21, 2004. <https://sccn.ucsd.edu/eeglab/>.
- [28] European Parliament and the Council of the European Union. Regulation (eu) 2016/679 of the european parliament and of the council of 27 april 2016 on the protection of natural persons with regard to the processing of personal data and on the free movement of such data, and repealing directive 95/46/ec (general data protection regulation). Official Journal of the European Union, 2016.
- [29] Yuqi Wang, Lijun Zhang, Pan Xia, Peng Wang, Xianxiang Chen, Lidong Du, Zhen Fang, and Mingyan Du. Eeg-based emotion recognition using a 2d cnn with different kernels. *Bioengineering*, 9(6):231, 2022.
- [30] Tooba Qazi, Fadwa Alatawi, Alishba Shah, and Steffen Hardt. Eeg-based emotion recognition using hybrid cnn and lstm classification. *Frontiers in Computational Neuroscience*, 16:Article 1019776, 2022.
- [31] Zhentao Huang, Yahong Ma, Rongrong Wang, Weisu Li, and Yongsheng Dai. A model for eeg-based emotion recognition: Cnn-bi-lstm with attention mechanism. *Electronics*, 12(14):3188, 2023. Submission received: 3 July 2023 / Revised: 20 July 2023 / Accepted: 21 July 2023 / Published: 22 July 2023.
- [32] OpenBCI. Openbci: Open source biosensing tools (eeg, emg, ekg, and more), 2024. Accessed: 2024-09-04.

APÉNDICE A

Código Desarrollado en el Proyecto

A.1 Tratamiento inicial del dataset SEED-V

```
1 % Definir los intervalos de cada sesion.
2 start_second1 = [30, 132, 287, 555, 773, 982, 1271, 1628, 1730, 2025,
3   2227, 2435, 2667, 2932, 3204];
4 end_second1 = [102, 228, 524, 742, 920, 1240, 1568, 1697, 1994, 2166,
5   2401, 2607, 2901, 3172, 3359];
6
7 start_second2 = [30, 299, 548, 646, 836, 1000, 1091, 1392, 1657, 1809,
8   1966, 2186, 2333, 2490, 2741];
9 end_second2 = [267, 488, 614, 773, 967, 1059, 1331, 1622, 1777, 1908,
10  2153, 2302, 2428, 2709, 2817];
11
12 start_second3 = [30, 353, 478, 674, 825, 908, 1200, 1346, 1451, 1711,
13  2055, 2307, 2457, 2726, 2888];
14 end_second3 = [321, 418, 643, 764, 877, 1147, 1284, 1418, 1679, 1996,
15  2275, 2425, 2664, 2857, 3066];
16
17 % Directorio que contiene los CNT Files de EEG.
18 cnt_directory = '..\EEG_raw';
19
20 % Directorio output con los archivos .set generados.
21 % El script de procesamiento de EEG trabaja con .set, por eso guardar
22   en
23   .set
24 output_directory = '..\MATLAB';
25
26 % Listar .cnt files del directorio
27 cnt_files = dir(fullfile(cnt_directory, '*.cnt'));
28
29 % Iterar sobre cada .cnt file
30 for file_idx = 1:length(cnt_files)
31   % Cargar .cnt file
32   cnt_file_path = fullfile(cnt_directory, cnt_files(file_idx).name);
33   EEG = pop_loadcnt(cnt_file_path);
34
35   % Resamplear a 400Hz.
36   EEG = pop_resample(EEG, 400);
37
38   % Comprobar el nuevo sampling rate.
39   srate = EEG.srate;
```

```

34 % El nombre de los archivos del SEED-V tienen el formato
35 % 'NumeroIndividuo_NumeroExperimento_NumeroExtra'. Separar usando '
36 % para identificar individuo y experimento.
37 file_parts = strsplit(cnt_files(file_idx).name, {'_', '.'});
38
39 % Guardar numero de individuo y numero de sesion.
40 numeroInd = file_parts{1};
41 session_number = str2double(file_parts{2});
42
43 % Seleccionar intervalos correctos para cada sesion.
44 switch session_number
45     case 1
46         start_second = start_second1;
47         end_second = end_second1;
48     case 2
49         start_second = start_second2;
50         end_second = end_second2;
51     case 3
52         start_second = start_second3;
53         end_second = end_second3;
54     otherwise
55         error('Unexpected session number: %d', session_number);
56 end
57
58 % Iterar sobre cada intervalo
59 for interval_idx = 1:length(start_second)
60     % Convertir cada los segundos a data points usando el sampling
61     % rate.
62     start_point = round(start_second(interval_idx) * srate);
63     end_point = round(end_second(interval_idx) * srate);
64
65     % Extraer el data segment
66     EEG_segment = pop_select(EEG, 'point', [start_point end_point])
67     ;
68
69     % Crear un nuevo file .set con el segmento.
70     numeroSegmento = num2str(interval_idx);
71     segment_filename = sprintf('%s_%d_%s.set', numeroInd,
72         session_number, numeroSegmento);
73     segment_filepath = fullfile(output_directory, segment_filename)
74     ;
75
76     % Guardar
77     pop_saveset(EEG_segment, 'filename', segment_filepath);
78 end
79 end

```

A.2 Algoritmo de preprocesamiento

```

1 % Inicializar EEGLAB
2 [ALLEEG, EEG, CURRENTSET, ALLCOM] = eeglab;
3
4 % Definir directorios

```

```
5 input_directory = '...\Set_Archives';
6 output_directory = '...\EEG_preprocessed';
7 channel_loc_file = '...\channel_62_pos.locs';
8
9 if ~exist(output_directory, 'dir')
10     mkdir(output_directory);
11 end
12
13 % Listar .set files del directorio.
14 set_files = dir(fullfile(input_directory, '*.set'));
15
16 % Procesar todos los archivos .set
17 for file_idx = 1:length(set_files)
18     try
19         % Cargar archivo .set
20         set_file_path = fullfile(input_directory, set_files(file_idx).
21             name);
22         EEG = pop_loadset('filename', set_files(file_idx).name, '
23             filepath', input_directory);
24         fprintf('Procesando archivo %d/%d: %s\n', file_idx, length(
25             set_files), set_files(file_idx).name);
26
27         % Eliminar los canales VEO, HEO, M1, M2
28         EEG = pop_select(EEG, 'nochannel', {'VEO', 'HEO', 'M1', 'M2'});
29         fprintf('Canales VEO, HEO, M1, M2 eliminados.\n');
30
31         % Importar las ubicaciones de los canales
32         EEG = pop_chanedit(EEG, 'load', {channel_loc_file 'filetype' '
33             locs'});
34         fprintf('Ubicaciones de los canales importadas.\n');
35
36         % Calcular la referencia promedio
37         EEG = pop_reref(EEG, []);
38         fprintf('Referencia promedio calculada.\n');
39
40         % Filtro de paso de banda 0.5-70 Hz
41         EEG = pop_eegfiltnew(EEG, 0.5, 70);
42         fprintf('Filtro de paso de banda aplicado.\n');
43
44         % Identificar canales malos usando la metrica de probabilidad
45         % con un umbral de 5
46         [~, bad_channels_prob] = pop_rejchan(EEG, 'elec', [1:EEG.nbchan
47             ], 'threshold', 5, 'norm', 'on', 'measure', 'prob');
48         fprintf('Canales malos identificados usando probabilidad.\n');
49
50         % Imprimir los canales malos identificados
51         fprintf('Canales malos identificados ( ndices ): %s\n', mat2str
52             (find(bad_channels_prob)));
53
54         % Seleccionar y eliminar los canales malos
55         EEG = pop_select(EEG, 'nochannel', find(bad_channels_prob));
56         fprintf('N mero de canales malos eliminados: %d\n', sum(
57             bad_channels_prob));
58
59         % ICA
60         EEG = pop_runica(EEG, 'extended', 1);
61         fprintf('ICA calculado.\n');
```

```

55     % Clasificar los componentes ICA
56     EEG = pop_iclabel(EEG, 'default');
57     fprintf('Componentes ICA clasificados.\n');
58
59     % Marcar y eliminar componentes no cerebrales
60     EEG = pop_icflag(EEG, [NaN NaN; 0.7 1; 0.7 1; 0.7 1; 0.7 1; 0.7
61         1; 0.7 1]);
62     fprintf('Componentes no cerebrales eliminados.\n');
63
64     % Guardar los datos preprocesados
65     [~, name, ~] = fileparts(set_files(file_idx).name);
66     output_file = fullfile(output_directory, [name '_preprocessed.
67         set']);
68     pop_saveset(EEG, 'filename', output_file);
69     fprintf('Archivo guardado: %s\n\n', output_file);
70
71     catch ME
72         fprintf('Error procesando el archivo: %s\n', set_files(file_idx
73             ).name);
74         fprintf('%s\n', ME.message);
75     end
76 end
77
78 fprintf('Procesamiento completo para todos los archivos.\n');

```

A.3 Extracción de características y concatenación de datos

```

1  import mne
2  import numpy as np
3  import matplotlib.pyplot as plt
4  import scipy.signal
5  from scipy.signal import stft, get_window
6  from scipy.stats import entropy
7  import os
8  import pickle
9
10 def cargar_eeg(filepath):
11     raw = mne.io.read_raw_eeglab(filepath, preload=True)
12     return raw
13
14 def add_channels(raw, target_n_channels=62):
15     n_channels = len(raw.ch_names)
16     if n_channels < target_n_channels:
17         mean_channel = np.mean(raw.get_data(), axis=0)
18         for i in range(n_channels + 1, target_n_channels + 1):
19             ch_name = f'EEG {i}'
20             info = mne.create_info(ch_names=[ch_name], sfreq=raw.info['
21                 sfreq'], ch_types='eeg')
22             new_raw = mne.io.RawArray(mean_channel[np.newaxis, :], info
23                 )
24             raw.add_channels([new_raw], force_update_info=True)
25
26 # Define frequency bands
27 bands = {

```

```
26     'delta': (1, 4),
27     'theta': (4, 8),
28     'alpha': (8, 14),
29     'beta': (14, 31),
30     'gamma': (31, 50)
31 }
32
33 # Compute Differential Entropy from STFT
34 def compute_de_from_stft(segment, fs=400):
35     window_size = int(fs * 1) # window size of 1 second
36     de_features = []
37     for band, (low, high) in bands.items():
38         # Compute the STFT with a Hanning window
39         f, t, Zxx = scipy.signal.stft(segment, fs=fs, window='hann',
40                                     nperseg=window_size, noverlap=0)
41         band_indices = np.where((f >= low) & (f <= high))[0]
42         if len(band_indices) == 0:
43             continue
44
45         band_power = np.abs(Zxx[band_indices, :])**2
46         band_power_mean = np.mean(band_power)
47         de = 0.5 * np.log(2 * np.pi * np.e * band_power_mean)
48         de_features.append(de)
49     return np.array(de_features).flatten()
50
51 input_dir = '../0.EEG_preprocessed'
52 output_dir = '../1.EEG_features'
53
54 # Listar todos los archivos .set en el directorio de entrada
55 for filename in os.listdir(input_dir):
56     if filename.endswith('.set'):
57         file_path = os.path.join(input_dir, filename)
58         raw = cargar_eeg(file_path)
59         add_channels(raw)
60
61         duration = 4
62         epochs = mne.make_fixed_length_epochs(raw, duration=duration,
63                                             preload=True, overlap=0)
64         all_de_features = []
65
66         for epoch_data in epochs.get_data():
67             epoch_features = []
68             for channel_data in epoch_data:
69                 de_features = compute_de_from_stft(channel_data, fs=raw
70                                                     .info['sfreq'])
71                 epoch_features.append(de_features)
72             all_de_features.append(np.concatenate(epoch_features))
73
74         all_de_features = np.array(all_de_features)
75
76         # Guardar las características en un archivo
77         output_file_path = os.path.join(output_dir, filename.replace('.
78                                     set', '_features.pkl'))
79         with open(output_file_path, 'wb') as f:
80             pickle.dump(all_de_features, f)
81
82     # Imprimir las dimensiones y un head de las primeras tres filas
```

```

80     print(f"Processed {filename}: features saved to {
      output_file_path}")
81     print("Shape of the features array:", all_de_features.shape)
82     print(all_de_features[:1])
83
84 # Definir el diccionario de etiquetas basado en la sesion y el trial
85 labels = {
86     1: ['Happy', 'Fear', 'Neutral', 'Sad', 'Disgust', 'Happy', 'Fear',
      'Neutral', 'Sad', 'Disgust', 'Happy', 'Fear', 'Neutral', 'Sad',
      'Disgust'],
87     2: ['Sad', 'Fear', 'Neutral', 'Disgust', 'Happy', 'Happy', 'Disgust',
      'Neutral', 'Sad', 'Fear', 'Neutral', 'Happy', 'Fear', 'Sad',
      'Disgust'],
88     3: ['Sad', 'Fear', 'Neutral', 'Disgust', 'Happy', 'Happy', 'Disgust',
      'Neutral', 'Sad', 'Fear', 'Neutral', 'Happy', 'Fear', 'Sad',
      'Disgust']
89 }
90
91 # Rutas de los archivos
92 ruta_archivos = r'...\1.EEG_features'
93 ruta_guardado = r'...\2.EEG_labels'
94
95 # Crear la ruta de guardado si no existe
96 os.makedirs(ruta_guardado, exist_ok=True)
97
98 # Funcion para procesar los archivos
99 def agregar_etiqueta_a_archivos(ruta_lectura, ruta_escritura):
100     for archivo in os.listdir(ruta_lectura):
101         if archivo.endswith('.pkl'):
102             # Extraer numeros de sesion y trial del nombre del archivo
103             partes = archivo.split('_')
104             if len(partes) >= 4:
105                 sesion = int(partes[1]) # Asumiendo que el segundo
                  elemento es la sesion
106                 trial = int(partes[2]) # Asumiendo que el tercer
                  elemento es el trial
107
108             # Cargar el archivo .pkl
109             with open(os.path.join(ruta_lectura, archivo), 'rb') as
                  f:
110                 data = pickle.load(f)
111
112             # Obtener la etiqueta correspondiente
113             etiqueta = labels[sesion][trial - 1]
114
115             # Crear una columna de etiquetas
116             etiqueta_columna = np.full((data.shape[0], 1), etiqueta
                  , dtype=object)
117
118             # Concatenar la columna de etiquetas al array de datos
119             data_con_etiqueta = np.hstack((data, etiqueta_columna))
120
121             # Guardar el nuevo archivo con la etiqueta a adida
122             nuevo_nombre_archivo = os.path.join(ruta_escritura,
                  archivo)
123             with open(nuevo_nombre_archivo, 'wb') as f:
124                 pickle.dump(data_con_etiqueta, f)

```

```
125         print(f"Archivo procesado y guardado: {
126             nuevo_nombre_archivo}")
127 # Ejecutar la funcion
128 agregar_etiqueta_a_archivos(ruta_archivos, ruta_guardado)
129
130 #ETIQUETAS A NUMERICO Y CONCATENAR
131
132 # Ruta de entrada de los archivos
133 ruta_entrada = r'...\2.EEG_labels'
134
135 # Ruta de salida para el archivo combinado
136 ruta_salida = r'...\3.EEG_concat\concatenated_features.csv'
137
138 # Asegurar que el directorio de salida existe
139 os.makedirs(os.path.dirname(ruta_salida), exist_ok=True)
140
141 # Diccionario de mapeo de etiquetas
142 label_mapping = {
143     'Disgust': 0,
144     'Fear': 1,
145     'Sad': 2,
146     'Neutral': 3,
147     'Happy': 4
148 }
149
150 def procesar_archivos_y_combinar(ruta_entrada):
151     dataframes = []
152
153     for archivo in os.listdir(ruta_entrada):
154         if archivo.endswith('.pkl'):
155             ruta_completa = os.path.join(ruta_entrada, archivo)
156             with open(ruta_completa, 'rb') as f:
157                 data = pickle.load(f)
158
159             # Asumimos que las etiquetas est n en la ultima columna
160             etiquetas_numericas = np.vectorize(label_mapping.get)(data
161                [:, -1].astype(str))
162
163             # Reemplazamos la ultima columna con las nuevas etiquetas
164             num ricas
165             data[:, -1] = etiquetas_numericas
166
167             # Convertimos el array a DataFrame
168             df = pd.DataFrame(data)
169             dataframes.append(df)
170
171             # Combinar todos los DataFrames en uno solo
172             df_combinado = pd.concat(dataframes, ignore_index=True)
173
174             # Renombrar la ultima columna a 'Label'
175             df_combinado.rename(columns={df_combinado.columns[-1]: 'Label'},
176                 inplace=True)
177
178     return df_combinado
179
180 # Llamar a la funcion y obtener el DataFrame combinado
181 df_final = procesar_archivos_y_combinar(ruta_entrada)
```

```

179
180 # Guardar el DataFrame final como CSV
181 df_final.to_csv(ruta_salida, index=False)
182
183 print("DataFrame combinado guardado en:", ruta_salida)

```

A.4 Modelos LSTM+CNN y LSTM Bidireccional

```

1 import pandas as pd
2 import numpy as np
3 from sklearn.model_selection import train_test_split
4 from sklearn.preprocessing import StandardScaler, LabelEncoder
5 from keras.utils import to_categorical
6 from keras.models import Sequential
7 from keras.layers import Conv1D, MaxPooling1D, Dropout, LSTM, Dense,
   BatchNormalization, Bidirectional
8 from keras.optimizers import Adam
9 from keras.regularizers import l2
10 from keras.callbacks import EarlyStopping, ReduceLROnPlateau
11 from sklearn.metrics import accuracy_score, classification_report
12 import matplotlib.pyplot as plt
13
14 # Leer los datos preprocesados
15 data_procesado = pd.read_csv('procesado.csv')
16 data_eeglab = pd.read_csv('procesado_eeglab.csv')
17
18 # DATASET SIN EEGLAB
19 X_procesado = data_procesado.iloc[:, :-1]
20 y_procesado = data_procesado.iloc[:, -1]
21
22 X_train_procesado, X_test_procesado, y_train_procesado,
   y_test_procesado = train_test_split(
23     X_procesado, y_procesado, test_size=0.2, random_state=42, stratify=
       y_procesado)
24
25 # DATASET CON EEGLAB
26 X_eeglab = data_eeglab.iloc[:, :-1]
27 y_eeglab = data_eeglab.iloc[:, -1]
28
29 X_train_eeglab, X_test_eeglab, y_train_eeglab, y_test_eeglab =
   train_test_split(
30     X_eeglab, y_eeglab, test_size=0.2, random_state=42, stratify=
       y_eeglab)
31
32 # Normalizacion
33 scaler = StandardScaler()
34
35 # Ajustar y transformar los datos
36 X_train_procesado_scaled = scaler.fit_transform(X_train_procesado)
37 X_test_procesado_scaled = scaler.transform(X_test_procesado)
38
39 X_train_eeglab_scaled = scaler.fit_transform(X_train_eeglab)
40 X_test_eeglab_scaled = scaler.transform(X_test_eeglab)
41

```

```
42 emotion_labels = {
43     0: 'Disgust',
44     1: 'Fear',
45     2: 'Sad',
46     3: 'Neutral',
47     4: 'Happy'
48 }
49
50 # LSTM + CNN
51
52 # Preprocesamiento de los datos
53 X_train_combined = X_train_eeglab_scaled.reshape(X_train_eeglab_scaled.
54     shape[0], 10, 31) # 10 ventanas temporales, 31 caracter sticas
55 X_test_combined = X_test_eeglab_scaled.reshape(X_test_eeglab_scaled.
56     shape[0], 10, 31) # 10 ventanas temporales, 31 caracter sticas
57
58 # Codificar las etiquetas
59 encoder = LabelEncoder()
60 y_train_encoded = encoder.fit_transform(y_train_eeglab)
61 y_test_encoded = encoder.transform(y_test_eeglab)
62
63 # Convertir las etiquetas a categoricas
64 y_train_categorical = to_categorical(y_train_encoded)
65 y_test_categorical = to_categorical(y_test_encoded)
66
67 # Crear el modelo CNN + LSTM
68 model_combined = Sequential()
69
70 # Capas CNN para extraer caracteristicas locales de las secuencias
71 model_combined.add(Conv1D(filters=64, kernel_size=3, activation='relu',
72     input_shape=(10, 31)))
73 model_combined.add(BatchNormalization())
74 model_combined.add(MaxPooling1D(pool_size=2))
75 model_combined.add(Dropout(0.3))
76
77 model_combined.add(Conv1D(filters=128, kernel_size=3, activation='relu',
78     ))
79 model_combined.add(BatchNormalization())
80 model_combined.add(MaxPooling1D(pool_size=2))
81 model_combined.add(Dropout(0.3))
82
83 # LSTM para capturar dependencias temporales
84 model_combined.add(LSTM(128, return_sequences=True))
85 model_combined.add(Dropout(0.4))
86 model_combined.add(LSTM(64))
87
88 # Capa densa para la clasificaci n final
89 model_combined.add(Dense(5, activation='softmax')) # Cambia '5' por el
90     n mero de clases
91
92 # Compilar el modelo
93 optimizer = Adam(learning_rate=0.0005)
94 model_combined.compile(loss='categorical_crossentropy', optimizer=
95     optimizer, metrics=['accuracy'])
96
97 # Entrenar el modelo
```

```

92 history = model_combined.fit(X_train_combined, y_train_categorical,
    epochs=80, batch_size=32, verbose=1, validation_data=(
    X_test_combined, y_test_categorical))
93
94 # Evaluacion del modelo
95 y_pred_categorical = model_combined.predict(X_test_combined)
96 y_pred = np.argmax(y_pred_categorical, axis=1)
97
98 accuracy_combined = accuracy_score(y_test_encoded, y_pred)
99 print("Evaluacion para el dataset 'procesado_eeglab' con CNN + LSTM:")
100 print("Reporte de Clasificacion:\n", classification_report(
    y_test_encoded, y_pred, target_names=list(emotion_labels.values())))
101 print("Accuracy:", accuracy_combined)
102
103 # Graficar Accuracy y Loss
104 plt.figure(figsize=(14, 5))
105
106 # Accuracy
107 plt.subplot(1, 2, 1)
108 plt.plot(history.history['accuracy'], label='Train Accuracy')
109 plt.plot(history.history['val_accuracy'], label='Validation Accuracy')
110 plt.title('Model Accuracy')
111 plt.xlabel('Epoch')
112 plt.ylabel('Accuracy')
113 plt.legend(loc='upper left')
114
115 # Loss
116 plt.subplot(1, 2, 2)
117 plt.plot(history.history['loss'], label='Train Loss')
118 plt.plot(history.history['val_loss'], label='Validation Loss')
119 plt.title('Model Loss')
120 plt.xlabel('Epoch')
121 plt.ylabel('Loss')
122 plt.legend(loc='upper left')
123
124 plt.show()
125
126 # LSTM BIDIRECCIONAL
127 # Preprocesamiento de los datos para el dataset 'procesado_eeglab'
128 X_train_lstm_eeglab = X_train_eeglab_scaled.reshape(
    X_train_eeglab_scaled.shape[0], 10, 31)
129 X_test_lstm_eeglab = X_test_eeglab_scaled.reshape(X_test_eeglab_scaled.
    shape[0], 10, 31)
130
131 # Definir el modelo LSTM bidireccional
132 model_eeglab = Sequential()
133 model_eeglab.add(Bidirectional(LSTM(128, return_sequences=True,
    kernel_regularizer=l2(0.001)), input_shape=(10, 31)))
134 model_eeglab.add(BatchNormalization())
135 model_eeglab.add(Dropout(0.5))
136
137 model_eeglab.add(Bidirectional(LSTM(128, return_sequences=True,
    kernel_regularizer=l2(0.001))))
138 model_eeglab.add(BatchNormalization())
139 model_eeglab.add(Dropout(0.5))
140
141 model_eeglab.add(LSTM(64, kernel_regularizer=l2(0.001)))
142 model_eeglab.add(BatchNormalization())

```

```
143 model_eeglab.add(Dropout(0.4))
144
145 model_eeglab.add(Dense(5, activation='softmax')) # Cambia 5 por el
      n mero de clases
146
147 # Compilar el modelo con una tasa de aprendizaje reducida
148 model_eeglab.compile(loss='categorical_crossentropy',
149                      optimizer=Adam(learning_rate=0.0005),
150                      metrics=['accuracy'])
151
152 # Implementar Early Stopping y ReduceLR0nPlateau
153 early_stopping = EarlyStopping(monitor='val_loss', patience=10,
      restore_best_weights=True)
154 reduce_lr = ReduceLR0nPlateau(monitor='val_loss', factor=0.5, patience
      =3, min_lr=1e-6)
155
156 # Entrenar el modelo
157 history = model_eeglab.fit(X_train_lstm_eeglab,
      y_train_categorical_eeglab,
158                           epochs=100, batch_size=32, verbose=1,
159                           validation_data=(X_test_lstm_eeglab,
      y_test_categorical_eeglab),
160                           callbacks=[early_stopping, reduce_lr])
161
162 # Evaluacion del modelo
163 y_pred_categorical_eeglab = model_eeglab.predict(X_test_lstm_eeglab)
164 y_pred_eeglab = np.argmax(y_pred_categorical_eeglab, axis=1)
165
166 print("Evaluacion para el dataset 'procesado_eeglab' con LSTM:")
167 print("Reporte de Clasificacion:\n", classification_report(
      y_test_encoded_eeglab, y_pred_eeglab, target_names=list(
      emotion_labels.values())))
168 print("Accuracy:", accuracy_score(y_test_encoded_eeglab, y_pred_eeglab)
      )
169
170 # Graficas de perdida y precision
171 plt.figure(figsize=(12, 6))
172 plt.subplot(1, 2, 1)
173 plt.plot(history.history['loss'], label='Train Loss')
174 plt.plot(history.history['val_loss'], label='Validation Loss')
175 plt.title('Model Loss')
176 plt.ylabel('Loss')
177 plt.xlabel('Epoch')
178 plt.legend()
179
180 plt.subplot(1, 2, 2)
181 plt.plot(history.history['accuracy'], label='Train Accuracy')
182 plt.plot(history.history['val_accuracy'], label='Validation Accuracy')
183 plt.title('Model Accuracy')
184 plt.ylabel('Accuracy')
185 plt.xlabel('Epoch')
186 plt.legend()
187 plt.tight_layout()
188 plt.show()
```

APÉNDICE B

Relación del TFG con los Objetivos
de Desarrollo Sostenible (ODS)



ANEXO

OBJETIVOS DE DESARROLLO SOSTENIBLE

Grado de relación del trabajo con los Objetivos de Desarrollo Sostenible (ODS).

Objetivos de Desarrollo Sostenibles	Alto	Medio	Bajo	No Procede
ODS 1. Fin de la pobreza.				X
ODS 2. Hambre cero.				X
ODS 3. Salud y bienestar.	X			
ODS 4. Educación de calidad.		X		
ODS 5. Igualdad de género.				X
ODS 6. Agua limpia y saneamiento.				X
ODS 7. Energía asequible y no contaminante.				X
ODS 8. Trabajo decente y crecimiento económico.		X		
ODS 9. Industria, innovación e infraestructuras.	X			
ODS 10. Reducción de las desigualdades.				X
ODS 11. Ciudades y comunidades sostenibles.				X
ODS 12. Producción y consumo responsables.				X
ODS 13. Acción por el clima.				X
ODS 14. Vida submarina.				X
ODS 15. Vida de ecosistemas terrestres.				X
ODS 16. Paz, justicia e instituciones sólidas.				X
ODS 17. Alianzas para lograr objetivos.				X



Reflexión sobre la relación del TFG/TFM con los ODS y con el/los ODS más relacionados.

El Trabajo de Fin de Grado (TFG) desarrollado en torno a la clasificación de emociones a partir de señales de electroencefalografía (EEG) tiene un enfoque multidisciplinario que aborda varios aspectos de los Objetivos de Desarrollo Sostenible (ODS) de la Agenda 2030 de las Naciones Unidas. Esta investigación, además de su enfoque técnico, tiene implicaciones éticas y sociales que están directamente relacionadas con el bienestar humano, la equidad y el desarrollo sostenible.

Uno de los ODS más relacionados con este trabajo es el ODS 3: Salud y bienestar, ya que la clasificación de emociones a través de señales EEG puede tener aplicaciones directas en el ámbito de la salud mental. El análisis de emociones a través de la tecnología EEG puede facilitar el diagnóstico temprano de trastornos mentales, como la depresión, la ansiedad o el trastorno de estrés postraumático, proporcionando una herramienta no invasiva que apoye a los profesionales de la salud en la monitorización y el seguimiento de los pacientes. En un mundo donde las enfermedades mentales se han convertido en una carga significativa para la salud pública, la posibilidad de contar con tecnologías avanzadas para medir el bienestar emocional y mental puede contribuir a mejorar el acceso a la atención médica y el tratamiento preventivo.

Además, el bienestar emocional y psicológico es un pilar importante del ODS 3, que busca garantizar una vida sana y promover el bienestar para todos en todas las edades. La tecnología que facilita una mejor comprensión de las emociones humanas puede ser clave en este sentido. De esta manera, el proyecto tiene el potencial de generar un impacto positivo en la salud pública, promoviendo mejores diagnósticos, tratamientos personalizados y una mayor calidad de vida para los individuos afectados por trastornos emocionales.

El proyecto también está vinculado al ODS 4: Educación de calidad, dado que la investigación en el ámbito de las interfaces cerebro-computadora no solo contribuye al avance del conocimiento científico, sino que también genera nuevas oportunidades para la formación y el aprendizaje. La implementación de este tipo de tecnologías podría ser utilizada en entornos educativos para evaluar el bienestar emocional de los estudiantes, creando condiciones de aprendizaje más favorables y personalizadas. Además, el uso de tecnologías avanzadas como el EEG en la investigación fomenta la innovación educativa y promueve el aprendizaje interdisciplinario, que es esencial para la formación de futuros profesionales capacitados para enfrentar los desafíos globales.

Asimismo, este trabajo ofrece una oportunidad para ampliar el acceso a tecnologías avanzadas en la educación superior. El desarrollo y la integración de herramientas tecnológicas en los planes educativos permiten a los estudiantes explorar áreas de innovación tecnológica como la inteligencia artificial, el procesamiento de señales



biomédicas y el análisis de emociones, temas de relevancia creciente en la educación moderna.

El ODS 9: Industria, innovación e infraestructura también está directamente relacionado con este trabajo. El proyecto involucra el desarrollo de tecnologías avanzadas y su aplicación en el análisis de emociones, contribuyendo a la creación de infraestructuras tecnológicas orientadas a la innovación en el campo de la neurociencia y la inteligencia artificial. Esta investigación fomenta la innovación en el uso de datos biomédicos para el bienestar humano, ayudando a que la industria tecnológica avance hacia soluciones más personalizadas y eficientes en el tratamiento de la salud mental.

El avance de este tipo de tecnologías en interfaces cerebro-computadora no solo abre nuevas posibilidades en el ámbito de la salud, sino también en otros sectores como el entretenimiento, la educación, y la mejora de la experiencia del usuario en general. Esta integración de tecnología avanzada en la vida cotidiana es un claro ejemplo de la implementación de infraestructuras innovadoras para el beneficio de la sociedad.

Este trabajo también puede vincularse al ODS 8: Trabajo decente y crecimiento económico. La investigación y el desarrollo de nuevas tecnologías relacionadas con el reconocimiento de emociones pueden generar nuevas oportunidades laborales en sectores como la neurociencia, la inteligencia artificial y la tecnología de interfaces cerebro-computadora. Estas áreas tecnológicas emergentes están creando una demanda creciente de profesionales capacitados, lo que impulsa el crecimiento económico y fomenta el empleo decente en sectores de alta tecnología.

El desarrollo de herramientas basadas en EEG también puede contribuir al bienestar en el entorno laboral, ofreciendo a las empresas la posibilidad de monitorizar el estado emocional de sus empleados, detectar posibles problemas de salud mental y mejorar el bienestar general en el lugar de trabajo.

En conclusión, el trabajo de fin de grado sobre la clasificación de emociones mediante EEG está estrechamente relacionado con varios de los Objetivos de Desarrollo Sostenible, en particular, los ODS 3, 4, 8 y 9. A través de la investigación y el desarrollo de tecnología avanzada, este trabajo contribuye a mejorar la salud y el bienestar de las personas, a fomentar la innovación tecnológica en la educación y la industria, y a generar nuevas oportunidades laborales en sectores emergentes. La tecnología desarrollada tiene el potencial de generar un impacto positivo en la sociedad, alineándose con los principios de sostenibilidad y equidad establecidos en la Agenda 2030 de las Naciones Unidas.