

Benemérita Universidad Autónoma de Puebla
Facultad de Ciencias de la Electrónica
Licenciatura en Electrónica



Tesis

Sistema de reconocimiento de emociones para apoyo psicológico
Que para obtener el título de:
Licenciado en Electrónica
PRESENTA:

C. Luis Gonzalo Salomón López

Directores de Tesis: Dra. María Monserrat Morín Castillo (FCE - BUAP)
Dr. José Rubén Conde Sánchez (FCFM - BUAP)

Enero 2025. Puebla, Pue. Méx.

Resumen

El estudio del reconocimiento de emociones humanas ha cobrado interés por sus aportaciones y aplicaciones en los ámbitos académico e industrial, aunque la mayoría de las técnicas de identificación, se enfocan en el análisis de imágenes faciales, en este trabajo se realizará el estudio a través del registro de los electroencefalogramas (EEG) que a pesar de ser menos explorado, permite capturar emociones apropiadamente, aunque con la limitante de la escasez de bases de datos disponibles. En neurología, el EEG se analiza con métodos de dominio de la frecuencia como la transformada de Fourier, pero, debido a la complejidad de estas señales, resulta más eficaz utilizar algoritmos de tiempo-frecuencia, esto es usando las transformadas Wavelet. La descomposición Wavelet, es una técnica usada en el análisis de EEG y valiosa para extraer sub-bandas de frecuencia. En esta tesis se presenta el desarrollo de una metodología basada en la transformada wavelet discreta para extraer sub-bandas de EEG para la detección y reconocimiento de cuatro emociones, consideradas básicas: felicidad, tristeza, miedo y estado neutral.

Índice general

Resumen	I
1. Introducción	1
1.1. Planteamiento del problema	2
1.2. Motivación	3
1.3. Justificación	3
1.4. Objetivos	4
1.5. Metodología	4
1.6. Organización de la tesis	5
2. Antecedentes	7
2.1. Marco teórico	10
2.2. Conceptos generales	10
2.2.1. Ondas cerebrales	10
2.2.2. Clasificación de ondas cerebrales	10
2.2.3. Biomarcadores	12
2.2.4. Regiones cerebrales	12
2.2.5. Electroencefalógrafo	13
2.2.6. Distribución de electrodos para electroencefalografía	14
2.3. Transformada wavelet continua	15
2.4. Transformada wavelet discreta	16
2.5. Codificación por subbandas	16
2.6. Estado del arte	18
2.7. Métodos de clasificación de emociones	18
2.7.1. Algoritmos de aprendizaje automático tradicional	18
2.7.2. Redes neuronales	20
2.7.3. Modelos híbridos	20
3. Desarrollo y Validación de Detección Emocional en Python	23
3.1. Obtención datasets públicos	23
3.1.1. Estructura del dataset	23
3.1.2. Preparación de entorno	24

3.1.3. Preparación de dataset	26
3.2. Acondicionar los datos	28
3.3. Extracción de características	30
3.3.1. Implementación transformada Wavelet	38
3.4. Decodificación de la emoción	47
3.5. Validación del sistema	56
3.5.1. Emoción del miedo	56
3.5.2. Emoción de la tristeza	58
3.5.3. Emoción estado neutral	59
3.5.4. Emoción de la felicidad	61
4. Resultados	63
5. Conclusiones	69
Bibliografía	71
Anexos	75

Capítulo 1

Introducción

Las emociones juegan un papel importante en la comunicación humana y pueden manifestarse de muchos modos, como pueden ser de forma verbal, o de forma no verbal, detectada mediante el tono de voz, gestos o expresiones corporales. Actualmente se ha prestado especial interés a los sistemas cerebro-computadora, que permitan establecer una interacción persona-computadora, sin embargo no todos los sistemas son tan eficientes como se espera, pues las limitantes que presentan son la capacidad de dar una interpretación emocional a los mismos, esto se debe a que no es posible identificar estados afectivos de las personas y utilizar esta información para ejecutar algunas acciones. Por otra parte, la identificación de las emociones desde la perspectiva de la psicología permite apoyarse y establecer diagnósticos más robustos en personas para las que es complicado comunicarse apropiadamente de manera verbal.

El objetivo de este trabajo es conocer el estado emocional de una persona a partir del registro de su electroencefalograma combinado con el uso de técnicas de filtrado. Esto es, se buscará determinar las emociones de miedo, tristeza, felicidad y estado neutral.

Por esta razón, desde una perspectiva psicológica, el estudio de las emociones es importante por la información que aporta al estado de salud mental y emocional de las personas bajo diversas condiciones. Las emociones, como complejas respuestas afectivas, influyen en la cognición, el comportamiento y el bienestar general. Al comprenderlas, los psicólogos pueden ayudar a las personas a manejar el estrés, la depresión, mejorar sus relaciones interpersonales, desarrollar una mayor autoconciencia y obtener información relevante para el seguimiento de su salud. Investigar las emociones permite descubrir patrones comunes y diferencias individuales, lo que enriquece la comprensión de la naturaleza humana.

En este contexto, la neurociencia afectiva [16] busca comprender como los procesos neuronales subyacen y afectan las emociones, los estados de ánimo y los comportamientos relacionados. En [16] se examina como los modelos de procesamiento predictivo pueden ofrecer nuevas perspectivas sobre las bases neurales de la experiencia afectiva. La neurociencia afectiva discute la incompatibilidad de estos modelos con la formulación tradicional del problema de inferencia inversa (modelos de procesamiento predictivo que

sugieren que los estados psicológicos son generados por patrones degenerados de actividad neuronal [24]) y se destaca la importancia de considerar la validez interna y externa en la investigación afectiva. También esta disciplina se centra en comprender cómo los procesos neuronales subyacen a las emociones y como estas influyen en la salud mental. Al estudiar la actividad cerebral relacionada con diferentes estados emocionales, los investigadores pueden identificar patrones y mecanismos que contribuyen a trastornos como la ansiedad y la depresión. La neurociencia afectiva no solo ayuda a desarrollar tratamientos más efectivos, sino que también ofrece herramientas para la prevención y el manejo del estrés, promoviendo así un bienestar emocional más equilibrado y una salud mental más robusta.

Actualmente, con el avance de la tecnología se cambia la forma en que se abordan los desafíos de la salud mental. La psicología va experimentando una evolución en la manera en que se diagnostican, tratan y monitorean los trastornos mentales. Contar con una herramienta que detecte las emociones de las personas traería consigo beneficios, como el acceso a la atención emocional y obtención de herramientas para el diagnóstico y tratamiento de trastornos mentales. Sin embargo, estos avances plantean desafíos éticos y prácticos que deben abordarse de manera cuidadosa y reflexiva [21].

Usar una interfaz BCI para conocer el estado emocional podría mejorar la calidad y la eficacia de las interfaces cerebro computadora, además de que abre nuevas formas para que los ordenadores entiendan el comportamiento o significado humano

En este contexto se pretende conocer las emociones de una persona a partir de una serie de señales electroencefalográficas y mediante la utilización de técnicas de filtrado. Esto es determinar si la persona está experimentando una emoción positiva o negativa, y su nivel de activación.

1.1. Planteamiento del problema

La comunicación emocional es una parte esencial de la interacción humana, permitiendo expresar y comprender los estados emocionales de uno mismo y de los demás. Sin embargo, para las personas con alteraciones emocionales, puede ser muy complejo interpretar sus sensaciones y sentimientos, lo que puede llevar a sentimientos de frustración, aislamiento social y una disminución en la calidad de vida.

Actualmente, existen diversas tecnologías disponibles para el reconocimiento de emociones en entornos controlados, pero estas soluciones suelen ser costosas, poco accesibles y no están adaptadas a las necesidades específicas de las personas con enfermedades o condiciones como el autismo [5]. Como adición a esto, muchas de estas tecnologías son desarrolladas por fuentes extranjeras, lo que provoca preocupaciones sobre la dependencia tecnológica y la falta de adaptación cultural y lingüística.

Ante este panorama, surge la necesidad de desarrollar un sistema de reconocimiento de emociones basado en una Interfaz Cerebro-Computadora (BCI) que sea accesible, efectivo y adaptado a las necesidades específicas de las personas con alteraciones emo-

cionales. Este sistema permitiría a estas personas comunicar sus emociones de manera más efectiva y autónoma [26].

Por lo tanto, la solución del problema se enfoca en la creación de soluciones tecnológicas accesibles y adaptadas para apoyar el tratamiento psicológico. Ante esta situación, surge la necesidad de desarrollar un sistema de reconocimiento de emociones que utilice señales EEG y coadyuve a proporcionar una evaluación objetiva del estado emocional de los pacientes, este sistema será capaz de detectar patrones distintivos de actividad cerebral asociados con diferentes estados emocionales y proporcionar retroalimentación útil para guiar el tratamiento y la intervención psicológica.

1.2. Motivación

Esta tesis está motivada por la creciente necesidad de aportar desarrollo tecnológico que apoye los tratamientos psicológicos, particularmente en el reconocimiento y manejo de las emociones. En la actualidad, la capacidad de comprender y gestionar las emociones es fundamental para el bienestar emocional y mental, pero muchos pacientes enfrentan dificultades para expresar o reconocer adecuadamente sus estados emocionales, aquí es donde el desarrollo tecnológico juega un papel importante. La integración de herramientas avanzadas como los sistemas de reconocimiento de emociones basados en señales EEG no solo permite una medición objetiva de los estados emocionales, sino que también proporciona una retroalimentación que puede mejorar la eficacia de las intervenciones psicológicas. Este enfoque no solo beneficia al terapeuta al ofrecer información precisa sobre el estado emocional del paciente, sino que también permite al paciente obtener una mayor comprensión de sus propias emociones. Esto facilita una comunicación más clara y directa entre el terapeuta y el paciente, lo que mejora el proceso terapéutico. Además, la combinación de tecnología y psicología en el contexto del reconocimiento de emociones responde a una demanda creciente de herramientas innovadoras que apoyen el bienestar emocional de la población. A medida que las tecnologías avanzan, es importante continuar desarrollando sistemas capaces de analizar con mayor precisión. [23].

1.3. Justificación

En los entornos de salud emocional, es necesario comprender e identificar algunas respuestas emocionales de los individuos durante interacciones sociales, visitas de familiares o de amigos, bajo diversas situaciones. La evaluación precisa de estas respuestas puede ser desafiante debido a la dificultad del paciente para comunicar sus emociones o la presencia de trastornos mentales que afectan su percepción y expresión emocional.

Para abonar en este tipo de oportunidades se propone desarrollar un sistema de detección de emociones basado en el análisis de sus señales cerebrales, esto es a partir

del registro de su electroencefalograma EEG, detectar respuestas emocionales de los individuos.

El objetivo principal es proporcionar información valiosa tanto para el personal clínico como para los familiares y amigos de los pacientes. Al analizar los datos EEG registrados se podrán identificar patrones emocionales y ofrecer una comprensión más profunda de las experiencias emocionales de los pacientes.

La implementación de este sistema plantea desafíos técnicos y éticos, como garantizar la privacidad y confidencialidad de los datos del paciente, así como validar los patrones EEG identificados como indicadores confiables de emociones, por lo que este sistema pretende sentar las bases para desarrollar un prototipo que coadyuve a mejorar la calidad de la atención en estos entornos al permitir una comprensión de las respuestas emocionales [10, 6].

1.4. Objetivos

Para alcanzar las metas de esta tesis, se proponen los siguientes objetivos.

Objetivo General

Sistema de reconocimiento de emociones para apoyo psicológico.

Objetivo Específicos

1. Analizar y acondicionar la información obtenida para unificar los datos.
2. Utilizar Transformada de Wavelet para extraer las características de la señal .
3. Clasificar las emociones desde el EEG para reconocer la emoción
4. Identificar y decodificar las emociones.
5. Validar el sistema de reconocimiento de emociones.

1.5. Metodología

Para lograr los objetivos se plantea una metodología que se muestra en la Figura 1.1 y que consta de las siguientes puntos:

1. **Obtención DataSets públicos:** Se obtendrán datasets públicos validados y clasificados en otros trabajos de investigación.
2. **Acondicionar los datos:** Se unificarán las frecuencias, así como conocer las características de los DataSets obtenidos para su posterior análisis.

3. **Extracción de Características (Transformada de Wavelet):** Se implementará el algoritmo utilizado la transformada de Wavelet continua ya que permite ajustar la escala de la función wavelet en tiempo y frecuencia. Esto la hace útil para el análisis de señales no estacionarias, como señales de audio y electroencefalogramas (EEG) [12].
4. **Decodificación de la emoción:** Se clasificarán: Alegría - Ira, Felicidad - Tristeza.
5. **Validación del sistema:** Se harán las pruebas pertinentes en sujetos para la validación del sistema, y que su uso sea correcto y sin daños al individuo.

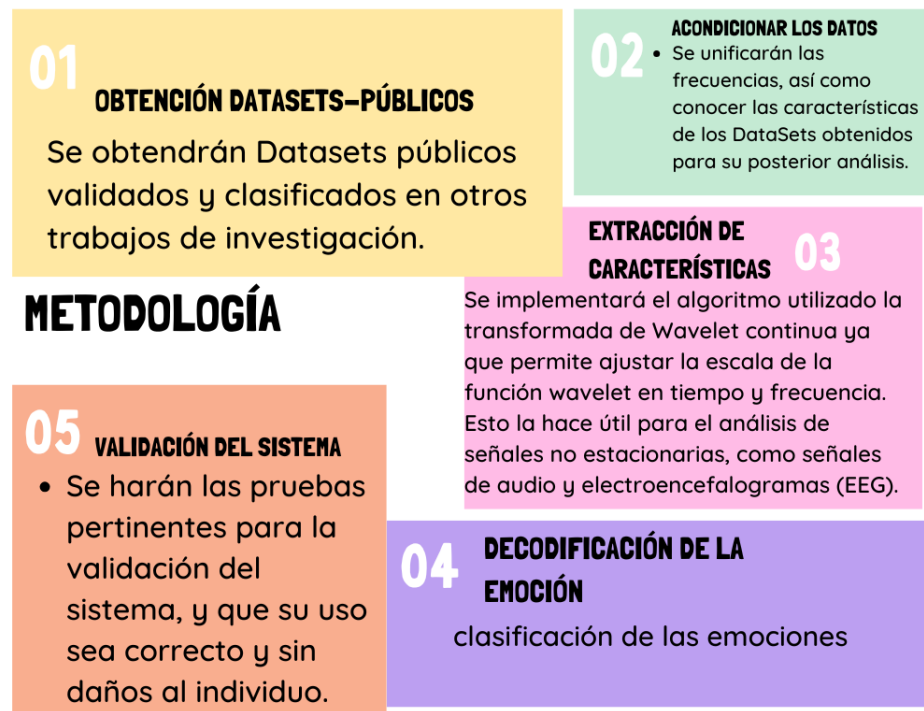


Figura 1.1: Diagrama a bloques propuesto.

1.6. Organización de la tesis

La tesis se encuentra organizada en cinco Capítulos, cuyo contenido se describe a continuación:

- Capítulo 1
En este capítulo podemos encontrar introducción, planteamiento del problema, motivación, justificación, objetivos (objetivo general y específicos) y metodología

- Capítulo 2

Aquí se aborda el marco teórico, donde se presentan y analizan los conceptos, teorías y modelos que forman la base de la investigación. El marco teórico es esencial para fundamentar el estudio y establecer el contexto en el cual se escribe el problema. Además, se incluyen los antecedentes del estudio, revisión de las investigaciones previas y el estado actual del conocimiento sobre el tema, lo que permite identificar trabajos existentes y justificar la relevancia de esta investigación.

- Capítulo 3

El capítulo 3 de la investigación aborda el desarrollo metodológico para la detección de emociones mediante electroencefalografía (EEG). Se describen los datos y herramientas utilizadas, el preprocesamiento de las señales, la extracción de características, y la implementación de modelos para identificar emociones. Además, se presentan los resultados obtenidos y se discuten sus implicaciones y limitaciones. Este capítulo es esencial para entender cómo se aplican los conceptos teóricos en la práctica de la detección de emociones a través de EEG.

- Capítulo 4

En este capítulo, se presentan y analizan los resultados obtenidos del estudio, detallando cómo se han aplicado los métodos descritos en capítulos anteriores para llegar a estos hallazgos. Se destacan los patrones observados en la detección de emociones a través de la electroencefalografía, incluyendo tanto los éxitos como las limitaciones del enfoque utilizado. Posteriormente, se presentan las conclusiones que se derivan de la investigación sobre la relevancia y las implicaciones de estos resultados en el campo de estudio. Finalmente, se incluye una bibliografía que documenta todas las fuentes y referencias utilizadas a lo largo del trabajo, proporcionando una base sólida para el estudio realizado.

Capítulo 2

Antecedentes

El estudio del cerebro ha sido desde siempre un tema interesante para el estudio y análisis de diferentes padecimientos como la epilepsia. Este supuesto se muestra en los hechos detectados desde 2000 A.C.; ya que se han encontrado documentos donde se muestra que en Mesopotamia, el imperio Acadio, Babilónico y Greco tenían conocimiento de la epilepsia, con lo cual el entenderla era primordial, se usaban técnicas terapéuticas para su tratamiento, debido a que en ese tiempo la epilepsia era denominado como la *enfermedad sagrada*, las terapias se dividían en 4 tipos: convencionales, marginales, trepanación y de origen religioso [9]. Siglos después y con el descubrimiento de la electricidad la cual marcó el comienzo de la era del estudio de las ondas eléctricas en la medicina [19]. Durante los inicios del siglo XVI y hasta el siglo XVII (1672) con William Gilbert Galileo y Thomas Willis, junto con Otto Von Guericke (desarrollador de Máquina de Fricción) investigaron sobre las propiedades de la electricidad induciendo corriente a diferentes medios.

En 1791, Luigi Galvani realizó un descubrimiento crucial para el desarrollo del electroencefalograma (EEG). Observó que las ancas de una rana se contraían en respuesta a la estimulación eléctrica, lo cual ocurría cuando tocaba sus nervios con unas tijeras durante una tormenta eléctrica [8].

En 1875, Richard Caton registró impulsos eléctricos utilizando un galvanómetro, el cual se empleaba para medir la corriente eléctrica en monos y ratas durante experimentos. Años más tarde, en 1929, el psiquiatra alemán Hans Berger, quien es reconocido como el pionero en el registro electroencefalográfico en humanos, descubrió la onda alfa en el cerebro. Berger demostró que esta onda aparece cuando el individuo está relajado y con los ojos cerrados, y desaparece cuando se encuentra concentrado en alguna actividad [4].

Hans Berger continuó el trabajo de Richard Caton, quien había experimentado con animales para estudiar la corriente eléctrica en el cerebro. Berger fue el primero en reportar sobre esta corriente en humanos, y el 6 de julio de 1924, registró el primer EEG durante una neurocirugía en un joven de 17 años. En 1929, publicó sus hallazgos sobre las ondas *alfa* y *beta*, marcando un hito en la comprensión de la actividad eléctrica cerebral [25].

Hans Berger estuvo motivado por el siguiente anécdota: *tuvo un accidente en el cual estuvo a al borde de la muerte y mientras se recuperaba recibió un mensaje por telegrama donde su hermana describía que ella sentía que estaba teniendo una sensación de que Berger estaba en peligro, a lo cual Berger pensó que de alguna forma su cerebro había mandado alguna señal a su hermana, todo esto teniendo en cuenta que en esa época la transmisión de mensajes sin cables era apoteósica, debido a lo sucedido Hans decidió investigar la comunicación psíquica* [25].

En 1934, el fisiólogo inglés ED Adrian y su colega HC Matthews [7] confirmaron las observaciones de Hans Berger utilizando amplificadores termoiónicos, los cuales confirmaron la presencia de ondas *alfa* en la región occipital del cerebro, con lo cual bautizaron esa observación con el nombre de *Ritmo de Berger*. A raíz de lo anterior y con el avance de la tecnología, se fue robusteciendo el concepto de EEG, y con la invención del primer ordenador de sobremesa; en 1964, los resultados obtenidos del EEG fueron plasmados en papel.

El EEG ha evolucionado con el avance de la tecnología, no solamente en cuanto a los dispositivos para realizar un registro, sino también para identificar diferentes aspectos en las señales electroencefalográficas, como en el uso que se les dará como: identificar alguna alteración por enfermedad, comportamientos normales para tener un parámetro de comparación, uso para videojuegos, identificación de emociones entre otros como lo desarrollan en [28]; y que además se resalta en particular el interés por el reconocimiento de emociones, el cual tiene sus raíces en la psicología, con estudios pioneros como los de Paul Ekman en la década de 1970 [22]. Ekman identificó seis emociones básicas (felicidad, tristeza, miedo, disgusto, sorpresa y enojo) que se manifiestan universalmente a través de expresiones faciales, específicamente en la conducta no verbal de las personas.

En las últimas décadas se han desarrollado diferentes sistemas que realizan simultáneamente registro de emociones, como el Sistema de Codificación de Acción Facial (FACS), la cual es una herramienta para medir y categorizar todas las posibles expresiones faciales humanas. Este sistema fue desarrollado por el psicólogo Paul Ekman y su colega Wallace V. Friesen en 1978 [22]. El objetivo del FACS es descomponer las expresiones faciales en unidades de acción, que son los movimientos específicos de los músculos faciales.

En 1994, Pascual-Marqui publica el algoritmo LORETA (Low Resolution Electromagnetic Tomography) [20], el cual realiza una recreación de la actividad eléctrica del cerebro a partir de los registros electroencefalográficos mostrando una tomografía en 3D, a partir del cuero cabelludo toma mediciones no invasivas a partir de las de diferencias de potencial eléctrico. Permitiendo el desarrollo del algoritmo para el registro, así como diferentes versiones mejoradas del mismo.

Recientemente y con el surgimiento de la IA (Inteligencia Artificial) se han creado softwares de aprendizaje automático que son capaces de reconocer cambios cerebrales causados por enfermedades como por ejemplo el Alzheimer [2]. Así mismo también hay algunos que pueden detectar personas potencialmente suicidas por medio de imágenes cerebrales anteriormente mapeadas que reconocen emociones como la ira y la vergüenza,

entre muchas otras cosas.

De manera más específica podemos abordar el tema de reconocimiento de emociones, las cuales tienen diferentes tipos de enfoques, uno de ellos es el reconocimiento de emociones por medio de gestos faciales. Para ello se sentarán las bases teóricas, que permitan soportar nuestra investigación.

Diversos autores han utilizado la transformación wavelet como herramientas de uso como lo hace Arpan Phukan en [22] en donde resalta la importancia de la transformación wavelet en el procesamiento de señales de EEG para capturar información relevante en diferentes escalas de tiempo y frecuencia, mejora la precisión en la clasificación de emociones.

2.1. Marco teórico

Se abordan los conceptos generales referente al trabajo de tesis, para que de esta forma, se pueda entender el funcionamiento de la diadema o equipo correspondiente con el que se realiza el registro, así como el circuito encargado de convertir los pulsos en señales eléctricas. Se comienza con conceptos generales, así como diferentes teorías para después utilizar algunas fórmulas y conceptos matemáticos. Posteriormente hacemos una revisión respecto a las técnicas de registro de señales eléctricas, finalizando con la explicación de los diferentes filtros.

2.2. Conceptos generales

2.2.1. Ondas cerebrales

La actividad eléctrica de conglomerados de neuronas puede ser registrada en el cuero cabelludo o incluso en la superficie del cerebro (corteza cerebral). El instrumento, a saber, un electroencefalógrafo el cual permite observar la amplitud y el patrón de estos registros, las cuales clasificados como normales influenciados por el estado del individuo, trastornos del sueño, la vigilia o la función cerebral de una persona, o enfermedades como epilepsia entre otras. Estas mediciones o registros se pueden observar en el EEG en formas de ondas y muestran los valores posibles así como las oscilaciones las cuales son llamadas ondas o ritmos cerebrales. Las ondas cerebrales obtenidas del cuero cabelludo tienen una amplitud de 0 a 200 microvoltios y un rango de frecuencia de 0,1 a 100 Hz. Las actividades en diferentes partes de la corteza cerebral son sensibles a los cambios entre la vigilia, el sueño y el coma. Muchas veces las ondas cerebrales son irregulares y no se puede captar patrones especiales en el EEG. En otros casos, surgen patrones claros, algunos de los cuales son muy característicos de ciertos trastornos cerebrales como la epilepsia. Por esta razón es importante identificar patrones de comportamiento considerado normal y realizar una clasificación, ésto para poder entender un poco mejor los conceptos comentados. A continuación se describirá el significado de ondas y las características de cada una de ellas.

2.2.2. Clasificación de ondas cerebrales

Las ondas cerebrales son patrones de actividad eléctrica en el cerebro que pueden ser medidos y analizados mediante técnicas como la EEG. Estas ondas se clasifican en diferentes tipos según su frecuencia y amplitud, y cada tipo de onda está asociado con diferentes estados mentales y actividades cerebrales, esta clasificación, se muestra en la Tabla 2.1 así como en la Figura 2.1. Se presenta una clasificación de las principales ondas cerebrales, destacando sus características, estado mental asociado, frecuencia. Es necesario destacar que son señales basales, considerando características de personas adultas.

Tipo de Onda	Frecuencia (Hz)	Características	Estado Mental Asociado
Delta (δ)	0.5 - 4	Alta amplitud, baja frecuencia	Sueño profundo, descanso sin sueños
Theta (θ)	4 - 8	Moderada amplitud, frecuencia intermedia	Somnolencia, meditación, estado de sueño ligero
Alpha (α)	8 - 13	Moderada amplitud, regularidad	Relajación, calma, estado de reposo con los ojos cerrados
Beta (β)	13 - 32	Baja amplitud, alta frecuencia	Alerta, atención, actividad mental intensa
Gamma (γ)	32 - 100	Muy baja amplitud, muy alta frecuencia	Procesamiento de información, percepción consciente

Tabla 2.1: Tipos de onda y sus características.




Figura 2.1: Ondas cerebrales humanas [Imagen tomada de <https://pogledi.net/en/brain-waves/>].

2.2.3. Biomarcadores

Según los Institutos Nacionales de Salud (NIH), un biomarcador es un “indicador medible de un proceso biológico normal, un proceso patológico, o la respuesta a una intervención terapéutica” [13]. Podemos encontrar diferentes tipos de biomarcadores, como se muestra en la Tabla 2.2.

Tipo de Biomarcador	Función	Ejemplo
Diagnósticos	Identifican una enfermedad o condición.	Niveles altos de glucosa para diagnosticar diabetes.
Pronósticos	Predicen cómo evolucionará una enfermedad.	Marcador PSA para evaluar el riesgo de cáncer de próstata.
De Respuesta	Indican cómo el organismo responde a un tratamiento.	Reducción de la presión arterial con antihipertensivos.
De Riesgo	Reflejan la probabilidad de desarrollar una enfermedad.	Niveles altos de colesterol sugieren riesgo cardiovascular.
De Exposición	Detectan la presencia de sustancias como toxinas o contaminantes en el cuerpo.	Concentración de nicotina indica exposición al tabaco.

Tabla 2.2: Tipos de biomarcadores, su función y ejemplos.

Sin embargo en este proyecto nos enfocamos por la actividad cerebral debido a que tiene varias limitantes, una de ellas es que las emociones no son estados discretos simples; por el contrario, son multidimensionales y pueden variar según el contexto cultural, social y personal. Por ejemplo, una señal fisiológica puede indicar tanto ansiedad como excitación positiva (ambas pueden activar respuestas similares, como un aumento en la frecuencia cardíaca o actividad beta en EEG). Las emociones también pueden superponerse; una persona puede experimentar tristeza y alivio simultáneamente, lo que es difícil de captar en biomarcadores.

2.2.4. Regiones cerebrales

La corteza cerebral que es la capa externa del cerebro se divide en 4 regiones, llamados lóbulos: frontal, parietal, occipital y temporal. Estas regiones están asignadas a funciones específicas, como la percepción, el pensamiento y el comportamiento humano, como se puede ver en la Figura 2.2.

El *lóbulo temporal* cubre una gran parte de la superficie del encéfalo e integra gran parte de la información sensorial, procesa la información de los contenidos de la visión, procesamiento de estímulos del sonido, de la misma forma este lóbulo es fundamental para habilidades como la memoria y el reconocimiento. Está ubicado a la altura de los

oídos el cual tiene mayor conexión con el sistema límbico, este sistema es una red de neuronas que tienen que ver directamente con la aparición de los estados emocionales.

El *lóbulo occipital* es el encargado de nuestro sistema visual-perseptivo, siendo el más pequeño de todos los lóbulos de la corteza cerebral con el 18 por ciento del volumen neocortical total. Se encuentra localizado en la parte posterior a los lóbulos parietal y temporal.

El *lóbulo parietal* se encuentra detrás del lóbulo frontal, los divide el surco central, una de sus características es que éste lóbulo trabaja en conjunto con otros, mezcla diferentes estímulos como aspectos visuales y sonidos, los junta y eso hace que se tenga una percepción completa de las cosas. También en este lóbulo se alojan ciertos recuerdos de informaciones sensoriales que nos llegan del mundo exterior. Por lo que podemos definir que su función es la de integrar estímulos de otros lóbulos.

El *lóbulo frontal* es el más grande de todos los lóbulos anteriores, se le atribuyen funciones como el criterio propio y aspectos que nos hacen seres racionales. Es el encargado del Meta-Pensamiento lo cual se refiere a la capacidad para pensar en abstracto sobre cosas que sólo están presentes en nuestra imaginación. Se encuentra situado como su nombre lo dice en la parte frontal del rostro.




Figura 2.2: Ondas cerebrales humanas [Imagen tomada de <https://www.tratamientoictus.com/lobulos-del-cerebro/>]

2.2.5. Electroencefalógrafo

El dispositivo permite medir la actividad eléctrica del cerebro y compararla a través de un proceso electrofisiológico. La detección de las ondas eléctricas emitidas por el cerebro se realiza mediante electrodos. Para obtener estas señales eléctricas, se colocan electrodos en la superficie del cuero cabelludo, utilizando un gel conductor para asegurar su adhesión. Estos electrodos se posicionan según el sistema 10-20, que se explicará en

detalle más adelante. La medición se basa en la diferencia de potencial entre cada canal, y los pares de electrodos se combinan para formar los montajes. Existen dos tipos básicos de montajes: bipolar y monopolar. El montaje bipolar mide la diferencia de potencial entre dos electrodos, colocados en áreas específicas de actividad cerebral. Para el caso del montaje monopolar, se mide la variación de voltaje entre un electrodo colocado donde hay actividad cerebral y entre otro donde no exista actividad.

2.2.6. Distribución de electrodos para electroencefalografía

Sistema 10-20

En un EEG la colocación de los electrodos en el cuero cabelludo son de importancia, en 1947 se acordó la unificación de un sistema que estandarizara la colocación de los electrodos en la cabeza con el cual se ideó el *sistema 10-20 EEG*, que se muestra en la Figura 2.3, [18]; así, el sistema 10-20 es un método utilizado internacionalmente, el cual necesita de puntos anatómicos como puntos ya establecidos o de referencia en la colocación de los electrodos en el EEG. este sistema requiere del uso de 20 electrodos. El sistema toma cuatro puntos de referencia craneales universales (nasion,inion y ambos puntos pre-auricular), y distribuye proporcionalmente los electrodos del EEG sobre la superficie de la cabeza, ver Figura 2.3. Para la colocación se siguen ciertas etiquetas dependiendo de las áreas de la corteza cerebral, estas etiquetas hacen referencia a las áreas que se están registrando por cada sensor.

Para las áreas son: frontopolar (Fp), frontal (F), central (C), temporal (T), parietal (P) y occipital (O). En cuanto a su ubicación lateralizada, los números impares (1, 3, 5, 7) se refieren a los electrodos colocados en el hemisferio izquierdo, mientras que los números pares (2, 4, 6, 8) se refieren a los del hemisferio derecho. Los electrodos que están sobre la línea media (línea cero) están etiquetados con la letra *z*.

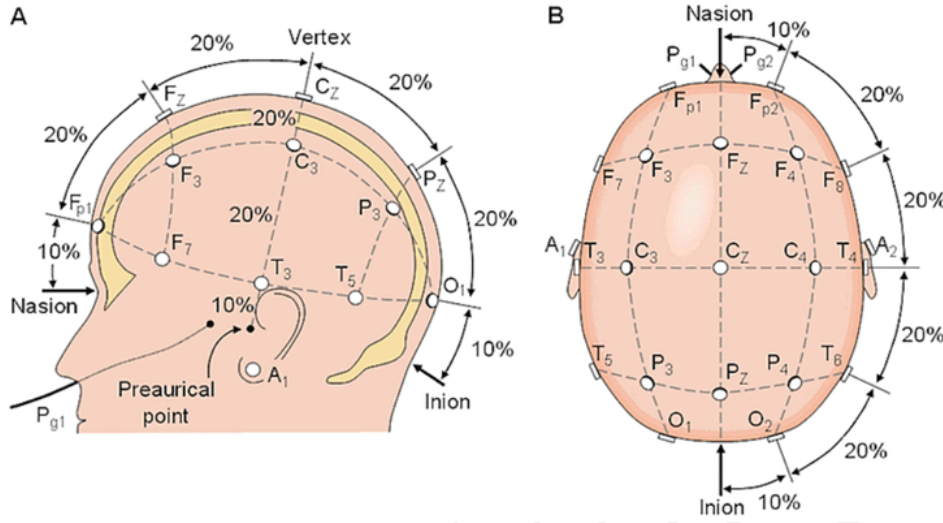


Figura 2.3: Distribución de electrodos en el sistema 10-20 [17].

2.3. Transformada wavelet continua

La Transformada Wavelet Continua (CWT) es una herramienta poderosa para analizar señales en los dominios del tiempo y la frecuencia simultáneamente. A diferencia de la Transformada de Fourier, que proporciona únicamente información sobre las frecuencias presentes en una señal, la CWT ofrece también una visión de cómo estas frecuencias varían con el tiempo.

La CWT de una señal $f(t)$ se define mediante la convolución de $f(t)$ con una familia de wavelets generada a partir de una función madre $\psi(t)$. La transformada se expresa matemáticamente como:

$$\text{CWT}_{\psi}\{f(t)\}(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} f(t) \psi^* \left(\frac{t-b}{a} \right) dt,$$

donde a y b son los parámetros de escala y traslación, respectivamente, y ψ^* denota el complejo conjugado de ψ . El parámetro de escala a controla el ensanchamiento o la compresión de la wavelet, mientras que el parámetro de traslación b desplaza la wavelet a lo largo de la señal.

Una de las principales ventajas de la CWT es su capacidad de proporcionar un análisis multirresolución, permitiendo examinar la señal en diferentes escalas o niveles de detalle. Esto es especialmente útil para analizar señales no estacionarias, donde las características de la señal pueden cambiar con el tiempo. Las wavelets, debido a su buena localización en tiempo y frecuencia, son ideales para este tipo de análisis.

La elección de la wavelet madre $\psi(t)$ es crucial y depende de la naturaleza de la señal que se está analizando. Algunas de las wavelets más comúnmente utilizadas incluyen la wavelet de Morlet, adecuada para el análisis de señales con componentes sinusoidales; la

wavelet de Haar, simple y computacionalmente eficiente, útil para señales con discontinuidades bruscas; y la wavelet de Daubechies, que ofrece una buena localización en el tiempo y la frecuencia, adecuada para una variedad de aplicaciones [1].

2.4. Transformada wavelet discreta

La Transformada Wavelet Discreta (DWT) es esencial en el análisis de señales y la compresión de datos. A diferencia de la Transformada Wavelet Continua (CWT), la DWT se aplica a señales discretas, utilizando un número finito de coeficientes wavelet, lo cual la hace computacionalmente eficiente y adecuada para aplicaciones digitales.

La DWT de una señal discreta $f[n]$ se obtiene al pasar la señal a través de filtros de análisis: un filtro pasa bajos $g[n]$ y un filtro pasa altos $h[n]$. Esto produce los coeficientes de aproximación $a_j[n]$ y los coeficientes de detalle $d_j[n]$, definidos como:

$$a_j[n] = \sum_k f[k]g[2n - k], \quad (2.1)$$

$$d_j[n] = \sum_k f[k]h[2n - k]. \quad (2.2)$$

La señal original se puede reconstruir mediante la transformada inversa, combinando los coeficientes de aproximación y detalle a través de filtros de síntesis. Una característica crucial de la DWT es su capacidad de proporcionar un análisis multirresolución, descomponiendo la señal en varios niveles de resolución. En cada nivel, los coeficientes de aproximación se descomponen aún más, proporcionando una representación detallada de la señal a diferentes escalas.

La DWT tiene varias propiedades beneficiosas: es computacionalmente eficiente con una complejidad de $O(N)$, donde N es el número de muestras en la señal; proporciona localización en tiempo y frecuencia, y es excelente para la compresión de datos debido a su capacidad de representar señales con pocos coeficientes significativos.

2.5. Codificación por subbandas

La codificación por subbandas usando wavelets es una técnica eficiente para la compresión de señales, empleada en el procesamiento de imágenes y audio. Este método descompone una señal original en diferentes subbandas de frecuencia mediante la Transformada Wavelet Discreta (DWT), lo que permite una representación más compacta y eficiente de la señal.

Para realizar esta descomposición, se aplica la DWT a la señal discreta $f[n]$, separándola en coeficientes de aproximación $a_j[n]$ y coeficientes de detalle $d_j[n]$ a través de filtros de análisis: un filtro pasa bajos $g[n]$ y un filtro pasa altos $h[n]$. Matemáticamente, estos coeficientes se calculan como:

$$a_j[n] = \sum_k f[k]g[2n - k],$$

$$d_j[n] = \sum_k f[k]h[2n - k].$$

La señal original puede ser reconstruida utilizando la transformada inversa, que combina los coeficientes de aproximación y detalle utilizando filtros de síntesis. La codificación por subbandas aprovecha esta descomposición multirresolución, descomponiendo iterativamente los coeficientes de aproximación en varios niveles de resolución, representados como:

$$f[n] \rightarrow \{a_1, d_1\} \rightarrow \{a_2, d_2, d_1\} \rightarrow \cdots \rightarrow \{a_J, d_J, \dots, d_1\},$$

donde J es el número de niveles de descomposición.

Una vez descompuesta la señal, los coeficientes wavelet $a_j[n]$ y $d_j[n]$ se cuantizan para reducir el número de bits necesarios para su representación. Esta cuantización puede ser uniforme o no uniforme, dependiendo de la aplicación. Posteriormente, los coeficientes cuantizados se codifican mediante técnicas de codificación de entropía, como la codificación de Huffman o la codificación aritmética, lo que reduce aún más el tamaño de los datos.

La codificación por subbandas usando wavelets ofrece varias ventajas significativas. Permite una compresión eficiente, logrando una reducción significativa en el tamaño de la señal original. Además, debido a la localización temporal y frecuencial de las wavelets, se minimizan los artefactos de compresión como los bloqueos, comunes en otros métodos. La capacidad de análisis multirresolución también facilita aplicaciones como el zoom progresivo en imágenes.

2.6. Estado del arte

La investigación en la clasificación de emociones mediante el uso de señales EEG sigue avanzando e impulsándose en parte por los desarrollos en el campo de la inteligencia artificial [27, 14, 29, 15, 3]. Este progreso permite una mayor comprensión del cómo las emociones se manifiestan en la actividad cerebral, así se avanza en la creación de dispositivos para la clasificación de las emociones.

El EEG, como se sabe, es una técnica no invasiva que registra la actividad eléctrica del cerebro a través de electrodos colocados en el cuero cabelludo. Las emociones humanas, que son estados complejos y multifacéticos, se reflejan en los patrones de actividad cerebral que el EEG capta. La clasificación de estas emociones a partir de señales EEG se ha convertido en un área de importancia, particularmente en aplicaciones como la interfaz cerebro-computadora (BCI), la salud mental, la realidad virtual, o como apoyo en el tratamiento psicológico. Es decir, sus aplicaciones van desde diferentes áreas interdisciplinarias hasta áreas específicas de investigación pura.

2.7. Métodos de clasificación de emociones

Los clasificadores de inteligencia artificial, incluidos los algoritmos de aprendizaje automático y las redes neuronales profundas, se emplean en la clasificación de emociones a partir de datos EEG [14]. Estos métodos se agrupan en varias categorías. Algunos autores como Ayan Seal en [27] menciona la existencia de bases de datos públicas limitadas de señales EEG en el campo de la computación afectiva, resaltando que la mayoría de los métodos actuales se centran en el reconocimiento de emociones a partir de señales fisiológicas como el EEG y el ECG. De manera similar Arpan Phukan en [22] presenta una revisión extensa de investigaciones relacionadas a la clasificación de emociones a partir de señales de EEG utilizando diversas técnicas y modelos, destacando la evolución de las redes neuronales convolucionales profundas, como *Xception*, y su aplicación en la extracción de características significativas de datos complejos, como imágenes.

2.7.1. Algoritmos de aprendizaje automático tradicional

Los algoritmos de aprendizaje automático como el Support Vector Machine (SVM), K-Nearest Neighbors (KNN) y Random Forest (RF) [3, 22] son algunos de los algoritmos utilizados para la clasificación de emociones. *Estos métodos requieren la extracción previa de características relevantes de las señales EEG, como la energía en diferentes bandas de frecuencia (delta, theta, alpha, beta, gamma), medidas estadísticas (media, varianza) y características no lineales.*

Support Vector Machine (SVM)

El SVM [29] que es un algoritmo de clasificación supervisada que encuentra el hiperplano óptimo que separa las clases en el espacio de características. El planteamiento matemático se define como:

$$\min_{\mathbf{w}, b, \xi} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \quad (2.3)$$

sujeto a:

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i = 1, \dots, n \quad (2.4)$$

donde \mathbf{w} es el vector de pesos, b es el sesgo, ξ_i son las variables de holgura, C es un parámetro de penalización y y_i son las etiquetas de clase.

K-Nearest Neighbors (KNN)

El KNN [29] es un algoritmo de clasificación basado en la distancia que asigna una clase a una muestra basada en las clases de sus k vecinos más cercanos en el espacio de características. La distancia comúnmente utilizada es la distancia euclidiana:

$$d(\mathbf{x}_i, \mathbf{x}_j) = \sqrt{\sum_{m=1}^M (x_{im} - x_{jm})^2} \quad (2.5)$$

donde \mathbf{x}_i y \mathbf{x}_j son vectores de características de las muestras.

Random Forest (RF)

El RF [29] es un conjunto de árboles de decisión que mejora la precisión y robustez del modelo mediante el promedio de múltiples árboles. Cada árbol se entrena con una muestra diferente del conjunto de datos, y la clasificación final se realiza por votación mayoritaria de los árboles.

$$h(x) = \operatorname{argmax}_y \sum_{t=1}^T I(h_t(x) = y) \quad (2.6)$$

donde $h_t(x)$ es la predicción del t -ésimo árbol, T es el número total de árboles e I es la función indicadora.

2.7.2. Redes neuronales

Las redes neuronales profundas (DNN) y las redes neuronales convolucionales (CNN) han revolucionado el campo al ofrecer una capacidad sin precedentes para el aprendizaje de características directamente de los datos brutos, eliminando en muchos casos la necesidad de extracción manual de características.

Redes Neuronales Convolucionales (CNN)

Las CNN son adecuadas para el reconocimiento de patrones espaciales en datos EEG. Utilizan capas convolucionales para extraer características jerárquicas:

$$y_{i,j,k} = f \left(\sum_{m,n,l} x_{i+m,j+n,l} \cdot w_{m,n,l,k} + b_k \right) \quad (2.7)$$

donde $y_{i,j,k}$ es la salida del mapa de características, $x_{i,j,l}$ es la entrada, $w_{m,n,l,k}$ son los pesos del filtro, b_k es el sesgo y f es una función de activación no lineal.

Redes Neuronales Recurrentes (RNN) y LSTM

Las RNN y LSTM (Long Short-Term Memory) son adecuadas para secuencias de datos y capturan la dinámica temporal en las señales EEG:

$$h_t = f(W_h \cdot h_{t-1} + W_x \cdot x_t + b_h) \quad (2.8)$$

donde h_t es el estado oculto en el tiempo t , W_h y W_x son matrices de pesos, x_t es la entrada y b_h es el sesgo.

2.7.3. Modelos híbridos

Esta clase de modelos combinan diferentes técnicas de aprendizaje como el *Transfer Learning* y las Redes Generativas Adversariales; estas técnicas buscan aportar en la generalización de los sistemas de clasificación de emociones.

El reconocimiento de emociones por *Transfer Learning* mejora la eficiencia de los sistemas ciberfísicos humanos en bucle (HilCPS) [31], esto es un tipo de sistema tecnológico que integra componentes físicos, computacionales y humanos en una interacción dinámica. Esto funciona de la siguiente manera: las señales de EEG, que reflejan los estados emocionales, se utilizan en combinación con el aprendizaje automático para la extracción de sus características y determinación de las emociones. Pero, dado que las muestras de EEG suelen ser insuficientes ya que presentan una no linealidad y complejidad para su procesamiento debido a falta de dispositivos de registro en los laboratorios de trabajo además de su alto costo, por lo que para superar estas limitaciones, se está propiciando el método ya mencionado, *Transfer Learning*, este permite aprovechar modelos preentrenados en grandes conjuntos de datos para mejorar el rendimiento en tareas específicas

de clasificación de emociones con datos limitados, mejora la calidad y cantidad de las muestras y clasifica con precisión los estados emocionales. Los experimentos muestran que este enfoque supera a los métodos tradicionales por lo que representaría un beneficio a la falta de datos para entrenar modelos complejos [31].

Las *redes generativas adversariales* se utilizan para la generación de datos sintéticos, ayudando a abordar la escasez de datos de entrenamiento en el dominio de EEG.

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}(x)}[\log D(x)] + \mathbb{E}_{z \sim p_z(z)}[\log(1 - D(G(z)))] \quad (2.9)$$

donde G es el generador, D es el discriminador, p_{data} es la distribución de datos reales y p_z es la distribución de ruido.

Este modelo integra técnicas de IA con enfoques multimodales que combinan EEG con otros datos fisiológicos y comportamentales para clasificar emociones. Buxon Fu en [11] presenta una investigación donde propone una red generativa adversarial condicional para mapear datos de EEG a imágenes faciales. Esto aborda la dificultad de etiquetar datos de EEG con precisión y mejora la visualización de emociones en la computación afectiva, generando expresiones faciales a partir de emociones registradas por EEG.

Capítulo 3

Desarrollo y Validación de Detección Emocional en Python

Para el desarrollo del trabajo se cuenta con una base de datos, donde se Utilizan una combinación de señales de ondas cerebrales y movimientos oculares para reconocer con precisión las emociones humanas. Para nuestro desarrollo, debemos primeramente recabar los datos a analizar, los cuales serán tomados de [30], los que fueron identificados después de la búsqueda realizada en el estado del arte, donde se encontró un *dataset* (*SEED*) público que se utiliza en el análisis de las señales. La información proporcionada en la base de datos fue delimitada para extraer la información requerida para este proyecto y que se describe a detalle más adelante.

3.1. Obtención datasets públicos

El conjunto de datos SEED-IV mencionado es de dominio público, validado y ampliamente utilizado en investigaciones relacionadas con la clasificación de señales de EEG para la identificación de emociones. Este dataset forma parte de una serie de recursos empleados que también son usados en estudios sobre interacción hombre-máquina, neurociencia y psicología, específicamente en el desarrollo y evaluación de sistemas de reconocimiento de emociones basados en señales cerebrales. SEED-IV incluye datos de EEG y movimientos oculares obtenidos de 15 participantes sanos, diestros, de entre 20 y 24 años, quienes realizaron el experimento en tres ocasiones en días distintos, acumulando un total de 45 pruebas. Este conjunto de datos está disponible para la comunidad académica como un recurso gratuito [30].

3.1.1. Estructura del dataset

La estructura del data set utilizado, esta generado de la siguiente manera: A los participantes se les provocan de las cuatro emociones siguientes: Felicidad, tristeza, miedo

y neutralidad., distribuidas en diferentes sesiones. Adicionalmente el *SEED-IV* incluye otras características, por ejemplo:

Electrodos de EEG: Señales registradas de varios electrodos colocados en el cuero cabelludo.

Frecuencia de muestreo: La tasa de registro de datos del EEG (comúnmente a 1 kHz, o frecuencia variable).

Duración de las grabaciones: de un a varios minutos.

Etiquetas de emociones: Indican la emoción que se intenta evocar durante cada segmento de la grabación. Los archivos fuente *.mat* contiene datos estructurados en una matriz bidimensional de tamaño (62, 33601). El número 62 representa los canales o electrodos del EEG en la grabación, es decir En este caso, hay 62 canales; el número 33601 representa el número de muestras de la señal de EEG.

Las etiquetas de las tres sesiones para los mismos sujetos son 0=neutra, 1=tristeza, 2=miedo y 3= felicidad, como se muestran a continuación:

- session1_label = [1, 2, 3, 0, 2, 0, 0, 1, 0, 1, 2, 1, 1, 1, 2, 3, 2, 2, 3, 3, 0, 3, 0, 3]
- session2_label = [2, 1, 3, 0, 0, 2, 0, 2, 3, 3, 2, 3, 2, 0, 1, 1, 2, 1, 0, 3, 0, 1, 3, 1]
- session3_label = [1, 2, 2, 1, 3, 3, 3, 1, 1, 2, 1, 0, 2, 3, 3, 0, 2, 3, 0, 0, 2, 0, 1, 0]

El tamaño de las ventanas temporales deslizantes para la extracción de características es de 4 segundos.

Un total de 15 sujetos participaron en el experimento. Para cada participante, se realizaron 3 sesiones en diferentes días, y cada sesión contenía 24 pruebas. En una prueba, el participante observaba uno de los clips de película, mientras se registraban sus señales de EEG y movimientos oculares con el sistema NeuroScan de ESI de 62 canales y gafas de seguimiento ocular SMI.

3.1.2. Preparación de entorno

Dado que las emociones están estrechamente vinculadas a la actividad cerebral en áreas específicas, particularmente en los lóbulos frontal y temporal. Se sabe que el lóbulo frontal es crucial para la regulación y expresión emocional, ahí se presenta una asimetría en su actividad: Por un lado, el hemisferio izquierdo está más relacionado con emociones positivas, como la alegría y la excitación, mientras que el hemisferio derecho se asocia con emociones negativas, como el miedo y la tristeza. Esta asimetría es conocida como la teoría de la *asimetría frontal* o *lateralización de las emociones*, y los electrodos son colocados en la región frontal (Fp1, Fp2, F3, F4, según el sistema 10-20 de EEG) son los que mejor capturan estas respuestas emocionales. Por otro lado, el lóbulo temporal, en particular la amígdala, juega un papel central en el procesamiento de emociones, especialmente las relacionadas con el miedo y las reacciones ante estímulos sociales. La combinación de electrodos en los lóbulos frontal y temporal permite una representación

más precisa de las emociones en los estudios de EEG. Por lo anterior, el desarrollo propuesto se centra en los canales $Fp1$, $Fp2$, $F3$ y $F4$.

Para garantizar una descripción adecuada del código, asegurando su compatibilidad con las extensiones de archivo y evitar errores en la compilación, es necesario utilizar librerías específicas que permitan ejecutar el código sin complicaciones, como se muestra en los siguientes algoritmos.

Algorithm 1 Importación de Bibliotecas y Preparación para Análisis de Datos

Inicio:

Importar la función `loadmat` de la biblioteca `scipy.io` para cargar archivos `.mat`

Importar la biblioteca `numpy` como `np` para operaciones numéricas

Importar la biblioteca `matplotlib.pyplot` como `plt` para visualización de datos

Importar la biblioteca `pandas` como `pd` para manipulación y análisis de datos

Importar la biblioteca `pywt` para análisis de ondas (Wavelet Transform)

Fin

Cada una de estas librerías tiene una función que a continuación se detalla: La biblioteca `scipy.io`, que forma parte de SciPy (*Scientific Python*), es útil cuando se trabaja con archivos de entrada y salida. En particular, la función `loadmat` de `scipy.io` se utiliza para cargar archivos `.mat` de MATLAB, lo que facilita la integración de datos de MATLAB en proyectos de Python.

Utilizar arreglos matriciales, realizar operaciones matemáticas y estadísticas, `numpy` es una herramienta esencial. Permite manejar arreglos (arrays) de manera eficiente, también realizar cálculos extenuantes y graficación.

`matplotlib.pyplot` es la biblioteca para generar una amplia variedad de gráficos.

La combinación de `scipy.io`, `numpy` y `matplotlib.pyplot` se convierte en un conjunto para la manipulación, análisis y visualización de datos científicos en Python, facilitando enormemente el trabajo en proyectos de investigación y desarrollo.

Además, `pywt` es otra biblioteca importante que se importa con `import pywt`. Permite utilizar las funcionalidades de PyWavelets, ofreciendo herramientas para trabajar con transformadas wavelet, esenciales tanto para el análisis como para el procesamiento de señales.

`pandas`, que se importa con `import pandas as pd`, es una biblioteca fundamental en Python para la manipulación y análisis de datos. Destaca por sus estructuras de datos flexibles como las Series unidimensionales, los DataFrames bidimensionales (similares a tablas en bases de datos o hojas de cálculo de Excel) y los paneles tridimensionales.

Instalar `pandas` es esencial para trabajar con datos estructurados, como tablas, bases de datos y archivos CSV. Esta biblioteca se instala fácilmente con el comando adecuado, y es una herramienta clave en el ecosistema de Python para el análisis y manipulación de datos.

3.1.3. Preparación de dataset

Cargar el dataset:

Algorithm 2 Cargar archivo `.mat` y preparar datos

Inicio:

Cargar las bibliotecas necesarias para el análisis de datos (`scipy.io`, `numpy`, `matplotlib`, `pandas`, `pywt`)

Definir la ruta del archivo `.mat` como `file_path`

Cargar los datos del archivo `.mat` utilizando la función `loadmat` y almacenarlos en `mat_data`

Fin

Se asignan las variables específicas para su análisis, en este paso, el objetivo principal es seleccionar y visualizar una señal EEG para comprender mejor los datos cargados desde el archivo `.mat`. Esto permite verificar la calidad de los datos, explorar las características de la señal y prepararla para realizar análisis más avanzados, como la transformada wavelet en pasos posteriores del código.

Algorithm 3 Imprime Variables y Selecciona Variable Específica para Análisis

```

1: Entrada: matData (datos en formato .mat)
2: Salida: Variables y su tamaño, eegData (datos de EEG)
3: {Imprimir Variables en el archivo .mat}
4: for all clave en matData.keys() do
5:   if la clave no comienza con -- then
6:     Imprimir clave: {matData[clave].shape}
7:   end if
8: end for
9: {Seleccionar una variable específica para análisis}
10: Seleccionar czEeg1
11: eegData = matData[czEeg1]

```

Como respuesta al código compilado, obtenemos lo siguiente señal sin filtrar, ver Figura 3.1:




Figura 3.1: Señal de un solo canal sin filtrar (lóbulo frontal)

En la Figura 3.2, se pueden observar todos los canales en conjunto:




Figura 3.2: Imagen de todos los canales en conjunto sin filtrar

en ella se puede notar que es casi indecifrable apreciar de manera correcta la señal del sujeto, y mucho menos analizarla, es por eso que se implementará la transformada wavelet para acotar, filtran y analizar la señal.

De manera consiguiente se realiza un filtrado con wavelet, dando como tope de frecuencia 60hz, esto debido a que es el rango más alto en el que los lóbulos cerebrales trabajan. Aplicando transformada de wavelet Daubechies se obtiene la imagen de la Figura 3.3

Podemos observar en la Figura 3.3 , la señal filtrada de un solo canal.




Figura 3.3: Señal filtrada

3.2. Acondicionar los datos

Para el acondicionamiento de los datos, se segmenta la señal en ventanas de tiempo de 1 y 2 seg., esto debido a que en el análisis de emociones a partir de señales de EEG, la segmentación en ventanas de tiempo nos permitirá examinar cómo varían las características de la señal dentro de cada intervalo temporal en respuesta a estímulos emocionales. Cada ventana representa un estado emocional particular o un evento relevante que se desea estudiar. Con el siguiente pseudocódigo se puede particionar la señal en diferentes ventanas de tiempo.

En la Figura 3.4 se muestra los diferentes canales en diferentes ventanas de tiempo, esto nos ayuda a poder visualizar mejor las señales, debido a una mejor visibilidad.

Se visualiza la descomposición de la de un canal dividido en diferentes canales por segundo, esto para ir mostrando el tratado de la señal con nuestro sistema.

Algorithm 4 Segmentación en ventanas de tiempo y visualización

Inicio**Definir parámetros:**

`window_size` \leftarrow Tamaño de la ventana en segundos

`window_samples` \leftarrow `window_size` \times `target_sampling_rate`

`num_windows` \leftarrow `len(eeg_data_downsampled_channel)` \div `window_samples`

Segmentación:

Crear una lista vacía `windows`

for `i = 0` **to** `num_windows - 1` **do**

`start` \leftarrow `i` \times `window_samples`

`end` \leftarrow `start` + `window_samples`

 Añadir `eeg_data_downsampled_channel[start:end]` a `windows`

end for

Convertir `windows` a un array de NumPy

Mostrar información:

Imprimir Número de ventanas \leftarrow `num_windows`

Imprimir Forma de cada ventana \leftarrow `windows.shape[1:]`

Visualización:

Crear una figura con tamaño (12, 6)

for `i = 0` **to** `min(num_windows, 5) - 1` **do**

 Graficar `np.arange(window_samples) / target_sampling_rate` contra `windows[i] + i \times 200`

 Etiquetar la gráfica como Ventana `i + 1`

end for

Título de la gráfica \leftarrow "Visualización de las primeras ventanas de tiempo"

Etiqueta del eje X \leftarrow "Tiempo (s)"

Etiqueta del eje Y \leftarrow "Valor (desplazado)"

Mostrar leyenda

Ajustar el diseño

Mostrar la gráfica

Fin




Figura 3.4: Señal de diferentes canales por separado

Dentro de la consola de visual estudio nos marca lo sig. :

Número de ventanas: 16

Forma de cada ventana: (120,)

El número de Ventanas es 16, este valor indica que la señal de EEG se ha dividido en 16 segmentos o ventanas de tiempo, es decir, la señal completa se ha particionado en 16 partes iguales, cada una de las cuales será tratada como una unidad independiente para el análisis posterior. El número 120, es el valor que indica la forma de cada ventana individual, significa que cada ventana contiene 120 muestras de datos, la frecuencia de muestreo después del re-muestreo es de 60 Hz y el tamaño de la ventana es de 2 segundos. Lo anterior se puede calcular con una fórmula sencilla: Número de muestras por ventana = Frecuencia de muestreo \times Duración de la ventana

Número de muestras por ventana = Frecuencia de muestreo \times Duración de la ventana

Número de muestras por ventana = *Frecuenciademuestreo* \times *anchodelaventana*

Número de muestras por ventana = 60 Hz \times 2 segundos = 120 muestras

3.3. Extracción de características

Antes de hacer la extracción de características, utilizaremos la Transformada Wavelet aplicada con Denoising, esta, descompone la señal en wavelets eliminando el ruido no estacionario para posteriormente reconstruirla, con esto permite mejorar la precisión de las características extraídas y la interpretación de los resultados.

Podemos ver un ejemplo en la Figura 3.5 del proceso de denoising, en este caso se le aplicó como prueba a diferentes tipo de ondas que se encuentran en el cerebro.

Algorithm 5 Generación, denoising y visualización de señales

Parámetros de la señal:Frecuencia de muestreo $fs \leftarrow 256$ HzTiempo $t \leftarrow np.arange(0, 1, 1/fs)$ **Generar señal en la banda gamma:**Frecuencia de la señal $f_signal \leftarrow 50$ HzSeñal $signal \leftarrow np.sin(2 * np.pi * f_signal * t)$ **Añadir ruido a la señal:**Fijar semilla para reproducibilidad $np.random.seed(0)$ Ruido $noise \leftarrow np.random.normal(0, 0.5, signal.shape)$ Señal con ruido $noisy_signal \leftarrow signal + noise$ **Parámetros de la Transformada Discreta de Wavelet (DWT):**Wavelet $wavelet \leftarrow 'db4'$ (Daubechies con 4 coeficientes)**Aplicar la Transformada Discreta de Wavelet (DWT):**Coeficientes $coeffs \leftarrow pywt.wavedec(noisy_signal, wavelet, level=4)$ **Umbralización:**Calcular $sigma \leftarrow np.median(np.abs(coeffs[-1])) / 0.6745$ Calcular $umbral \quad threshold \quad \leftarrow \quad sigma * np.sqrt(2 * np.log(len(noisy_signal)))$ Aplicar umbral a los coeficientes $coeffs_denoised \leftarrow [pywt.threshold(c, threshold, mode='soft') \text{ for } c \text{ in } coeffs]$ **Reconstruir la señal a partir de los coeficientes umbralizados:**Señal denoised $denoised_signal \leftarrow pywt.waverec(coeffs_denoised, wavelet)$ **Visualización:**

Crear figura con tamaño (12, 8)

Subgráfico 1:Graficar $signal$ Título $\leftarrow 'Señal Original en la Banda Gamma (50 Hz)'$ Etiqueta del eje X $\leftarrow 'Tiempo (s)'$ Etiqueta del eje Y $\leftarrow 'Amplitud'$ **Subgráfico 2:**Graficar $noisy_signal$ Título $\leftarrow 'Señal con Ruido'$ Etiqueta del eje X $\leftarrow 'Tiempo (s)'$ Etiqueta del eje Y $\leftarrow 'Amplitud'$ **Subgráfico 3:**Graficar $denoised_signal$ Título $\leftarrow 'Señal Denoised'$ Etiqueta del eje X $\leftarrow 'Tiempo (s)'$ Etiqueta del eje Y $\leftarrow 'Amplitud'$

Ajustar el diseño

Guardar gráfico como $'denoising_signal_gamma.png'$ **Fin**




Figura 3.5: Proceso de denoising (eliminación de ruido) aplicado a una señal en la banda Gamma (50 Hz)

Implementar la transformada de Wavelet nos permite ajustar la escala de la función wavelet en tiempo y frecuencia. Esto la hace útil para el análisis de señales no estacionarias, como señales de audio y electroencefalogramas (EEG) [12]. Una vez aplicado denoising y definiendo el umbral, podemos hacer la extracción de características, de forma frecuencial y de manera estadística para cada tipo de onda.

De forma frecuencial:

Cabe destacar que en la extracción de características tenemos números los cuales indican cuánta energía hay en cada banda de frecuencia en la señal EEG, esto es útil para analizar patrones específicos de la actividad cerebral en cada segmento. Estos valores se utilizan como data para modelos de aprendizaje automático o para interpretar cambios en la actividad neuronal. En la Figura 3.6 se observa la señal en banda Gamma aplicando denoising, para ver como va funcionando este método de filtrado.

Así mismo en la Figura 3.7 vemos el denoising aplicando a la señal en banda Theta, se puede observar que el ruido proveniente de las señales funciona. De la similar, en la Figura 3.8 se observa como se modifica la señal al aplicar denoising.

Algorithm 6 Denoising de señal y espectrograma por banda de frecuencia

Entrada: Señal EEG, frecuencia de muestreo fs , diccionario de bandas EEG $bands$

Salida: Espectrograma por cada banda de frecuencia $wavelet_denoising_signal$, $wavelet='db4'$, $level=4$ Aplicar la descomposición wavelet con $wavedec$ Calcular el umbral basado en la desviación estándar de los coeficientes de detalle Aplicar la umbralización suave a los coeficientes de detalle Reconstruir la señal denoised con $waverec$

Retornar: Señal denoised $plot_spectrogram_signal$, fs , $band_name$, $freq_range$ Definir los parámetros de la wavelet Morlet compleja Calcular las escalas para la Transformada de Wavelet Continua (CWT) Aplicar CWT a la señal denoised para obtener coeficientes y frecuencias Graficar la señal original y el espectrograma Limitar el rango de frecuencias al de la banda de interés Mostrar el gráfico cada banda $band$ en el diccionario $bands$ Obtener el rango de frecuencias para $band$ Aplicar $wavelet_denoising$ a la señal EEG Aplicar $plot_spectrogram$ a la señal denoised

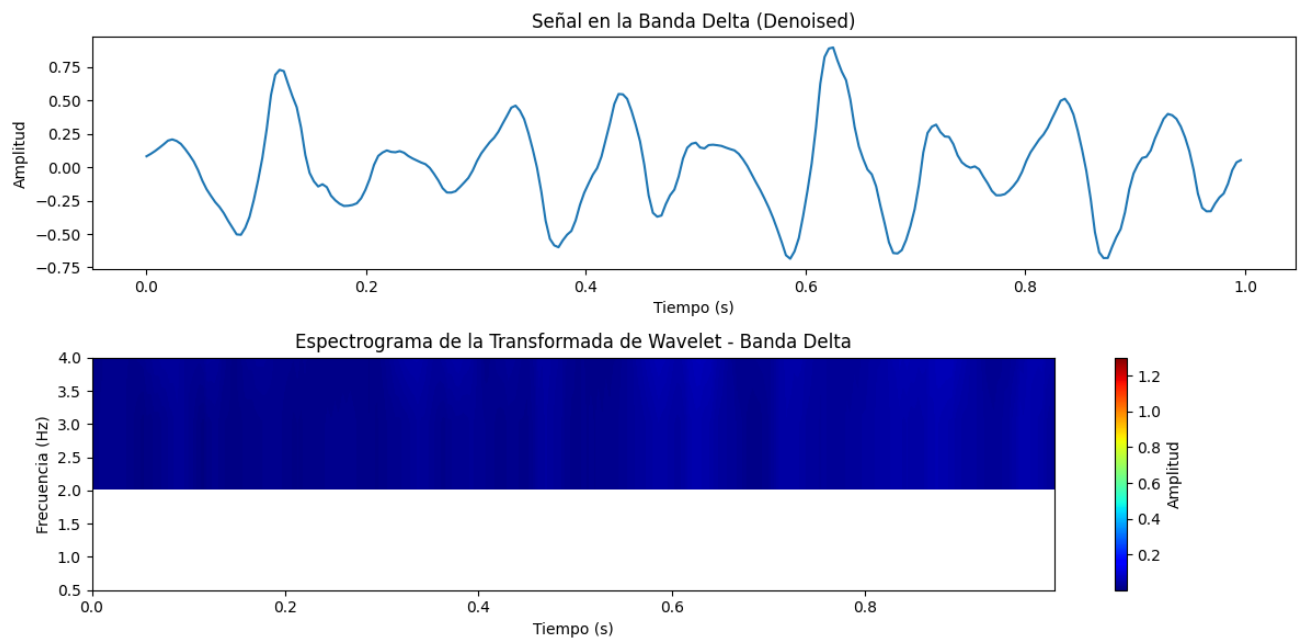


Figura 3.6: Análisis temporal y frecuencial de una señal en la banda Gamma

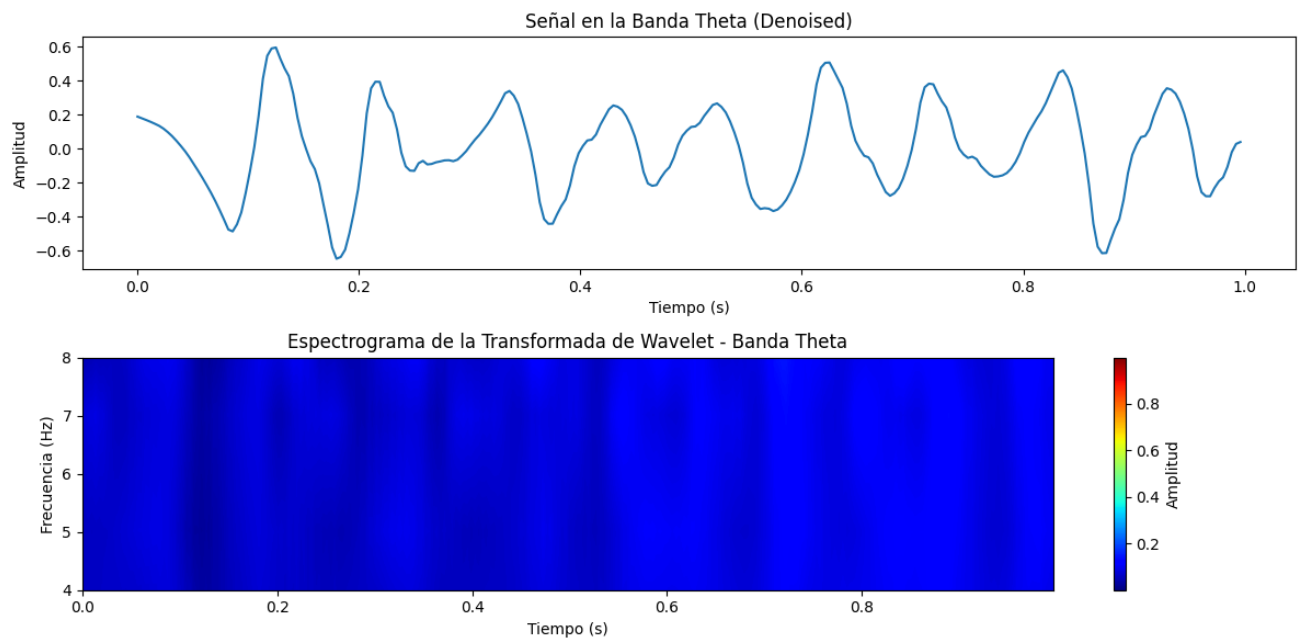


Figura 3.7: Análisis temporal y frecuencial de una señal en la banda Theta

Denoising aplicado a la señal, se observa en la Figura 9 la forma de la señal una vez aplicado el filtrado.

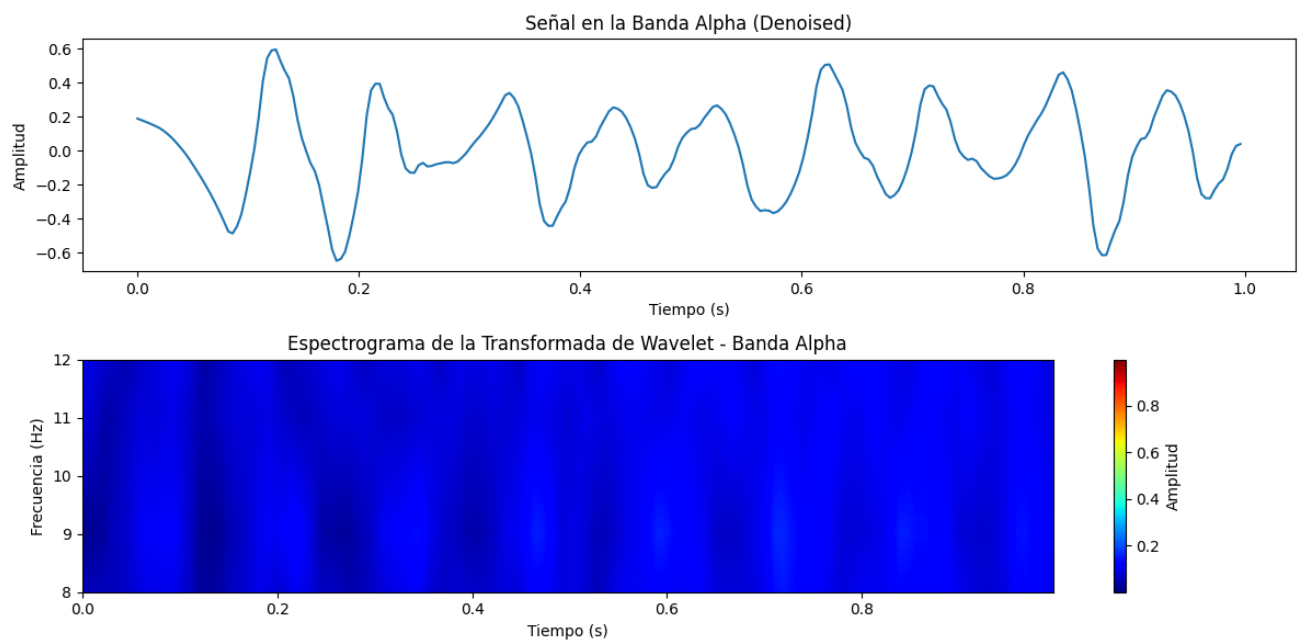


Figura 3.8: Análisis temporal y frecuencial de una señal en la banda Alpha

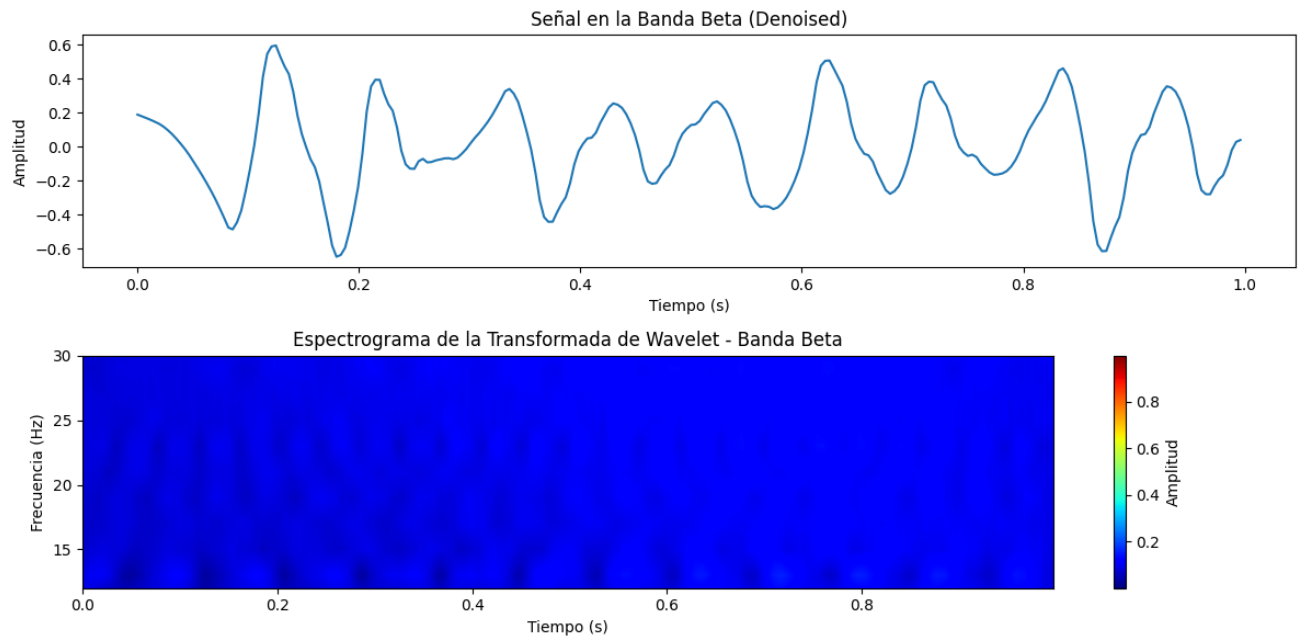


Figura 3.9: Análisis temporal y frecuencial de una señal en la banda Beta

Y por último se le aplica denoising a la señal en en banda Gamma como se muestra en la Figura 3.10.

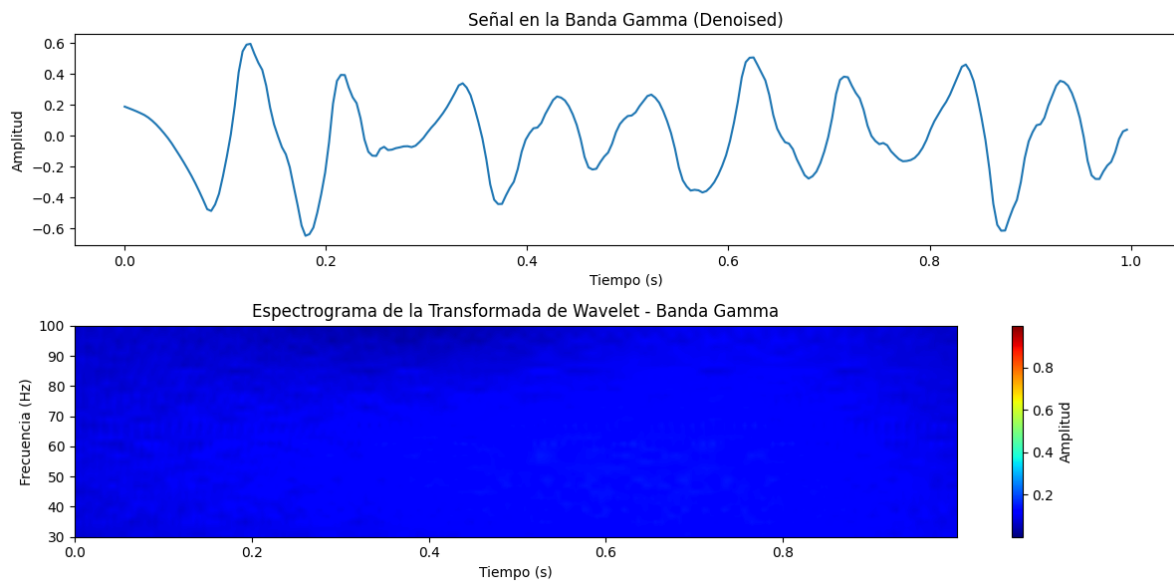


Figura 3.10: Análisis temporal y frecuencial de una señal en la banda gamma

Una vez cargado el archivo *vcs* y cargadas dentro del dataset las etiquetas de las emociones (happy, sad, neutral), se extraeran las características. Para eso implementaremos

el siguiente código:

Dentro del código tenemos el comando PCA (por sus siglas en inglés Análisis de Componentes Principales). El PCA es una técnica estadística utilizada para reducir la dimensionalidad de un conjunto de datos, conservando al mismo tiempo la mayor cantidad posible de variabilidad presente en los datos. En el contexto del análisis de características de EEG: PCA, es utilizado para reducir las características originales a un número menor de componentes principales que explican la variabilidad de los datos de manera más eficiente. En el código, se realiza PCA para visualizar las características de EEG en un espacio bidimensional (PCA1 y PCA2), lo que facilita la comprensión de las relaciones y patrones entre las observaciones de EEG en un formato más fácil de visualizar y analizar.

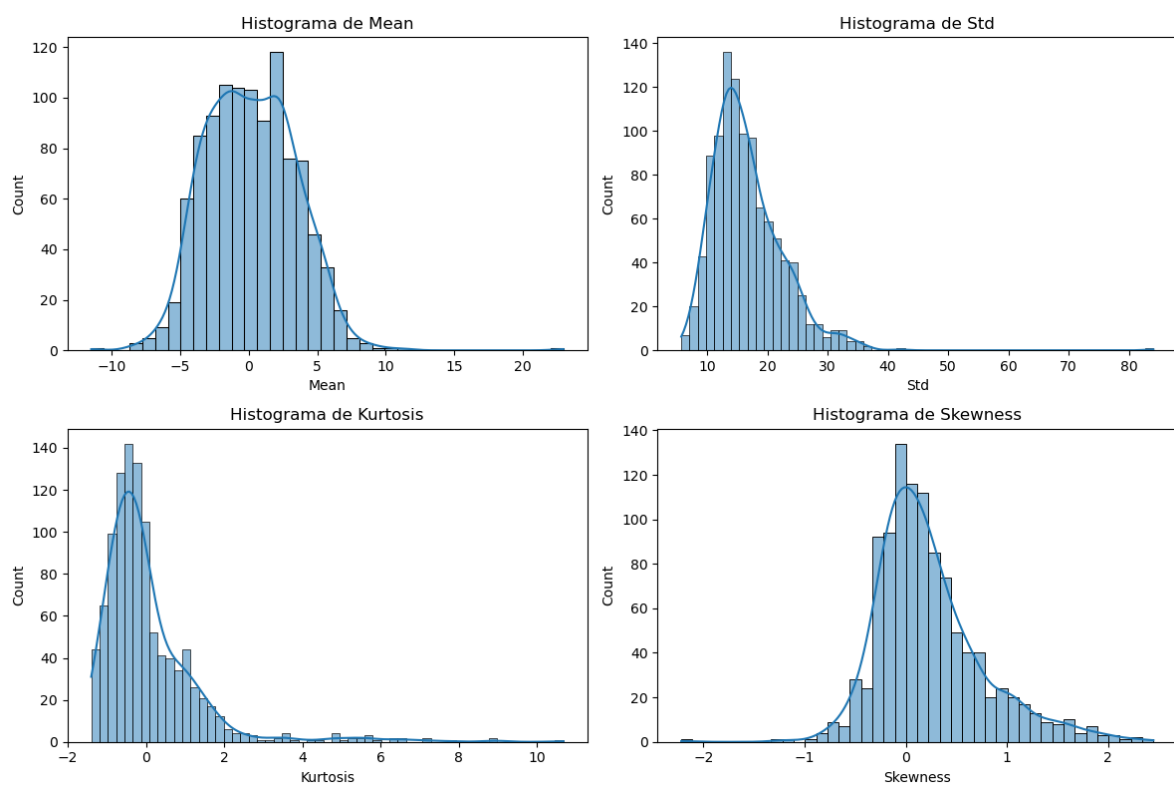


Figura 3.11: Características en forma estadística

Los histogramas, "MEAN,STD,KURTOSIS,KNEWNESS", son cuatro características de los datos de los EEG, Media (Mean), Desviación Estándar (Std), Curtosis (Kurtosis) y Asimetría (Skewness). Estos gráficos son útiles para entender la distribución de estas características en el conjunto de datos.

En la Figura 3.11 tenemos que en el Histograma de Media (Mean): La mayoría de los valores de la media están alrededor de 0 a 5. Hay una cola larga hacia la derecha, lo

que sugiere que hay algunos valores atípicos (outliers) con medias más altas.

Histograma de Desviación Estándar (Std):

La distribución está sesgada a la derecha, con la mayoría de los valores entre 10 y 25. Hay algunos valores más altos que sugieren variabilidad significativa en algunos segmentos de los datos.

La desviación estándar (Std) en señales EEG normales están en un rango de 10 a 50 V. En situaciones de alta actividad la desviación estándar puede superar los 50 V. En EEGs de baja amplitud (sueño profundo), podría estar entre 5 y 20 V.

Histograma de Curtosis (Kurtosis): La mayoría de los valores de curtosis están entre -1 y 1. Hay una cola larga hacia la derecha, lo que indica que hay segmentos con picos más pronunciados en comparación con una distribución normal.

Como norma, kurtosis en señales EEG no estacionarias suele estar entre 3 y 10. Que se acerque a un valor de 3 indica una señal más cercana a la normalidad, a diferencia que si excede este valor significa la presencia de eventos de gran amplitud, como parpadeos o artefactos musculares. En estados con actividad cerebral intensa o movimientos, la kurtosis puede llegar a valores mayores de 10, reflejando picos prominentes en la señal.

Histograma de Asimetría (Skewness): La mayoría de los valores de asimetría están alrededor de 0, lo que sugiere una distribución simétrica. Hay colas hacia ambos lados, indicando la presencia de algunos valores con asimetría positiva y negativa.

En general, el skewness en EEG no estacionario, puede variar entre -1 y 1. Cuando hay artefactos o actividad asimétrica, estos valores pueden moverse fuera de este rango, con skewness positivo si predominan las amplitudes altas y skewness negativo si predominan las bajas.

Una vez obtenidas las características vamos a asignar las etiquetas a cada número de ventanas:

1. Leer 'eeg_features.csv' y almacenar en features_df
2. Contar las filas en features_df y almacenar en num_windows
3. Imprimir "Número de ventanas en eeg_features.csv: {num_windows}"

4. Importar pandas como pd

5. Establecer num_windows = 1054

6. Generar etiquetas:
 - a. Crear lista labels['happy', 'sad', 'neutral'] hasta cubrir num_windows
 - b. Cortar lista labels para que tenga exactamente num_windows elementos

7. Verificar que el número de etiquetas coincide con el número de ventanas
 - a. Asegurarse de que `len(labels) == num_windows`, si no, lanzar error
8. Crear DataFrame `labels_df` con columna 'label' usando lista `labels`
9. Guardar `labels_df` en 'eeg_labels.csv'
10. Imprimir "Archivo 'eeg_labels.csv' creado exitosamente con {num_windows} etiquetas."

3.3.1. Implementación transformada Wavelet

En la implementación de la transformada wavelet podemos obtener las siguientes características.

Energía de los Coeficientes: Indica la cantidad de energía presente en cada nivel de frecuencia.

Media y Desviación Estándar: Proporcionan una medida de la centralidad y la dispersión de los coeficientes.

Asimetría y Curtosis: Ofrecen información sobre la forma de la distribución de los coeficientes, lo cual es útil para detectar irregularidades o patrones específicos.

1. **Respuesta en Frecuencia del Filtro Pasa Bajos de Descomposición:** Este gráfico muestra cómo el filtro pasa bajos aplicado durante la fase de descomposición atenúa las frecuencias superiores a aproximadamente 0.3 Hz.
2. **Respuesta en Frecuencia del Filtro Pasa Altos de Descomposición:** Aquí se muestra cómo el filtro pasa altas aplicado en la descomposición permite pasar las frecuencias superiores a aproximadamente 0.3 Hz, mientras que atenúa las frecuencias más bajas.
3. **Respuesta en Frecuencia del Filtro Pasa Bajos de Reconstrucción:** Similar al primer gráfico, pero aplicado en la fase de reconstrucción de la señal. Este filtro también atenúa las frecuencias superiores a 0.3 Hz.
4. **Respuesta en Frecuencia del Filtro Pasa Altos de Reconstrucción:** Este gráfico muestra el comportamiento del filtro pasa altos en la fase de reconstrucción, permitiendo el paso de frecuencias superiores a 0.3 Hz y atenuando las inferiores.

En todos los gráficos, se observa un comportamiento característico de los filtros pasa bajos y pasa altos, que es esencial para el proceso de descomposición y reconstrucción de señales en la transformada wavelet. Los filtros utilizados son parte de la familia de wavelets "db7" (Daubechies 7), conocidos por sus propiedades de ortogonalidad y compacidad en el dominio del tiempo.

Estos gráficos son útiles para entender cómo los filtros aplicados afectan las distintas componentes frecuenciales de la señal durante el procesamiento wavelet, permitiendo una separación efectiva de las frecuencias bajas y altas tanto en la descomposición como en la reconstrucción de la señal original.

Algorithm 7 Análisis y Graficado de Respuestas en Frecuencia de Wavelet

Require: Wavelet (ej. 'db7')

Ensure: Gráficas de respuestas en frecuencia

- 1: Definir wavelet \leftarrow 'db7'
 - 2: Definir nivel de descomposición \leftarrow 1
 - 3: Obtener filtros de wavelet:
 - 4: $(dec_lo, dec_hi, rec_lo, rec_hi) \leftarrow$ Wavelet(wavelet).filter_bank
 - 5: Calcular respuesta en frecuencia de filtros de descomposición:
 - 6: $freq_response_dec_lo \leftarrow$ FFT(dec_lo , 1024)
 - 7: $freq_response_dec_hi \leftarrow$ FFT(dec_hi , 1024)
 - 8: Calcular respuesta en frecuencia de filtros de reconstrucción:
 - 9: $freq_response_rec_lo \leftarrow$ FFT(rec_lo , 1024)
 - 10: $freq_response_rec_hi \leftarrow$ FFT(rec_hi , 1024)
 - 11: Definir frecuencias para el eje x:
 - 12: $frequencies \leftarrow$ FFTFreq(1024)
 - 13: Graficar respuestas en frecuencia de descomposición:
 - 14: Crear figura
 - 15: Subgráfica 1:
 - 16: Graficar $frequencies[: 512]$ vs $|freq_response_dec_lo[: 512]|$
 - 17: Graficar $frequencies[: 512]$ vs $|freq_response_dec_hi[: 512]|$
 - 18: Graficar respuestas en frecuencia de reconstrucción:
 - 19: Subgráfica 2:
 - 20: Graficar $frequencies[: 512]$ vs $|freq_response_rec_lo[: 512]|$
 - 21: Graficar $frequencies[: 512]$ vs $|freq_response_rec_hi[: 512]|$
 - 22: Mostrar gráficas
-

En la Figura 3.12 se muestran los gráficos de la respuesta en frecuencia de los filtros wavelet "db7" para la descomposición y reconstrucción de señales.




Figura 3.12: Descomposición y reconstrucción de señales usando la transformada wavelet de Daubechies (db7).

A continuación, se detallan los elementos presentes en cada gráfico:

El gráfico izquierdo muestra la respuesta en frecuencia de la descomposición usando db7, en el eje 'Y' (Magnitud) muestra la magnitud de la respuesta en frecuencia. En el eje 'X' muestra las frecuencias en Hz.

La Línea azul representa la descomposición pasa bajas 'db7', la cual es la respuesta en frecuencia del filtro pasa bajos utilizado durante la descomposición. Observamos que tiene una magnitud alta para frecuencias bajas y disminuye a medida que aumenta la frecuencia, alcanzando valores cercanos a cero para frecuencias más altas (por encima de 0.3 Hz).

La línea naranja muestra la respuesta en frecuencia del filtro pasa altos utilizado durante la descomposición. Tiene una magnitud baja para frecuencias bajas y aumenta a medida que la frecuencia se incrementa, alcanzando su máximo en frecuencias más altas (por encima de 0.3 Hz).

Gráfico Derecho: Respuesta en Frecuencia de la Reconstrucción usando db7 En el eje 'Y' se representa la magnitud de la respuesta en frecuencia. El eje X muestra las frecuencias en Hz.

La línea azul es la respuesta en frecuencia del filtro pasa bajos utilizado durante la reconstrucción. Al igual que en el filtro de descomposición, tiene una magnitud alta para frecuencias bajas y disminuye a medida que aumenta la frecuencia. Con respecto a la

naranja se asocia con la frecuencia del filtro pasa altos utilizado durante la reconstrucción. Similar al filtro de descomposición, tiene una magnitud baja para frecuencias bajas y aumenta con la frecuencia.

Algorithm 8 Generación y Visualización de Señales EEG

Require: Frecuencia de muestreo $fs \leftarrow 512$ Hz

Require: Duración de la señal $t \leftarrow 1$ segundos

- 1: *Definir vector de tiempo:*
- 2: $time \leftarrow \text{arange}(0, t, 1/fs)$
- 3: *Definir frecuencias centrales:*
- 4: $delta_freq \leftarrow 2$ Hz
- 5: $theta_freq \leftarrow 6$ Hz
- 6: $alpha_freq \leftarrow 10$ Hz
- 7: $beta_freq \leftarrow 22$ Hz
- 8: $gamma_freq \leftarrow 65$ Hz
- 9: *Generar ondas utilizando la función seno:*
- 10: $delta_wave \leftarrow \text{sen}(2\pi \cdot delta_freq \cdot time)$
- 11: $theta_wave \leftarrow \text{sen}(2\pi \cdot theta_freq \cdot time)$
- 12: $alpha_wave \leftarrow \text{sen}(2\pi \cdot alpha_freq \cdot time)$
- 13: $beta_wave \leftarrow \text{sen}(2\pi \cdot beta_freq \cdot time)$
- 14: $gamma_wave \leftarrow \text{sen}(2\pi \cdot gamma_freq \cdot time)$
- 15: *Sumar todas las ondas para crear la señal compuesta:*
- 16: $composite_signal \leftarrow delta_wave + theta_wave + alpha_wave + beta_wave + gamma_wave$
- 17: *Visualizar las señales individuales y la señal compuesta:*
- 18: Crear figura
- 19: **for** cada tipo de onda **do**
- 20: Subgráfica: Graficar onda
- 21: Título: 'Nombre de la onda'
- 22: Ejes: Tiempo vs Amplitud
- 23: **end for**
- 24: Graficar $composite_signal$
- 25: Título: 'Composite Signal'
- 26: *Mostrar gráficas*

En la Figura 3.13 muestra las formas de onda de diferentes tipos de señales EEG, así como una señal compuesta que es la suma de todas ellas. Aquí hay un desglose de cada parte de la imagen:

Delta Wave (2 Hz): Esta onda tiene una frecuencia de 2 Hz. Las ondas delta son las ondas cerebrales más lentas y están asociadas con el sueño profundo y la meditación profunda.

Theta Wave (6 Hz): Esta onda tiene una frecuencia de 6 Hz. Las ondas theta están

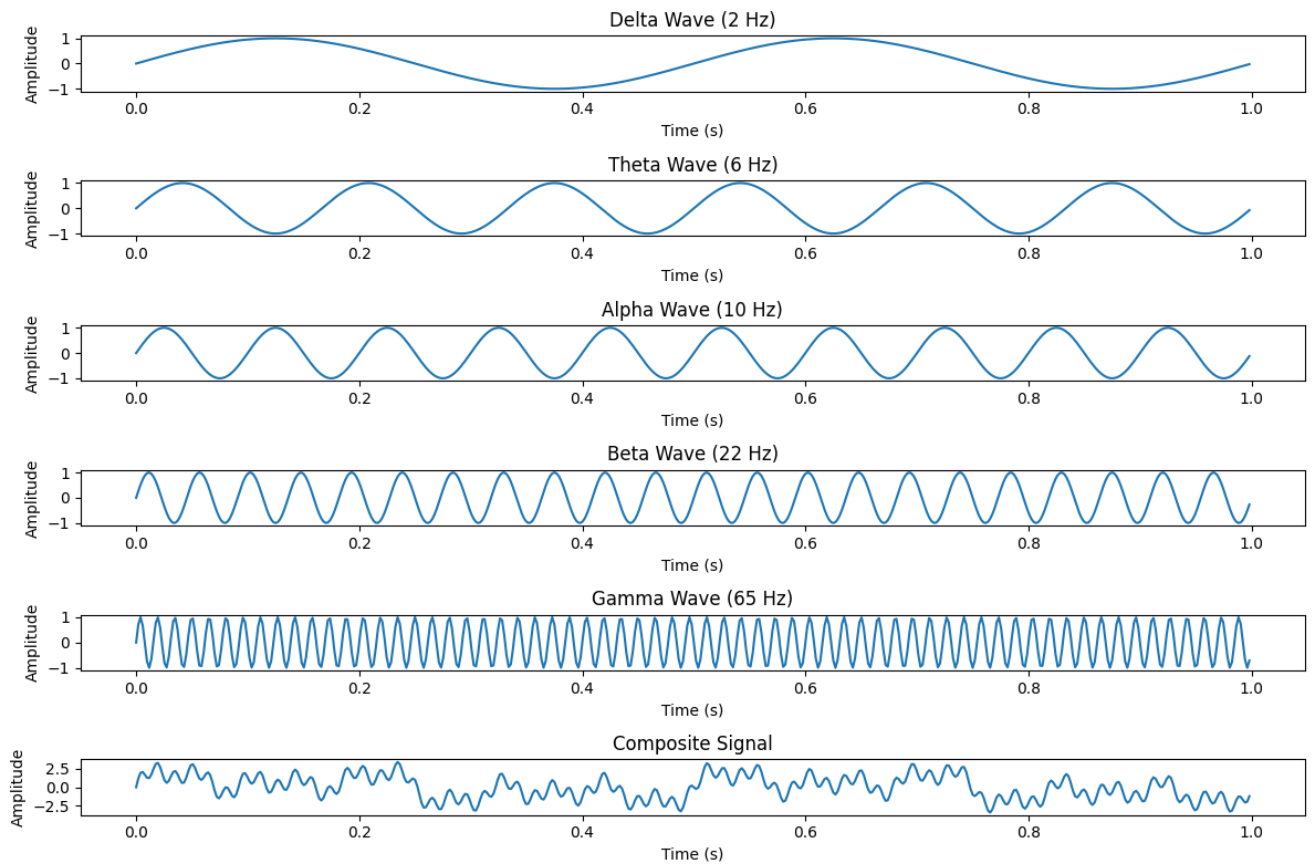


Figura 3.13: Respuesta en Frecuencia.

asociadas con el sueño ligero, la relajación profunda y los estados de meditación.

Alpha Wave (10 Hz): Esta onda tiene una frecuencia de 10 Hz. Las ondas alfa están asociadas con la relajación cuando se está despierto, a menudo vistas en estados de calma y meditación.

Beta Wave (22 Hz): Esta onda tiene una frecuencia de 22 Hz. Las ondas beta están asociadas con el pensamiento consciente, la concentración y la actividad mental activa.

Gamma Wave (65 Hz): Esta onda tiene una frecuencia de 65 Hz. Las ondas gamma están asociadas con la alta actividad cerebral, la percepción y la conciencia.

En la Figura 3.14 muestra las respuestas en frecuencia de los filtros de descomposición y reconstrucción para las wavelets Daubechies (db2, db4 y db7). Define las wavelets y parámetros iniciales en diferentes niveles de descomposición ('db2', 'db4', 'db7').

Los filtros pasa bajos (líneas azules) tienen una alta magnitud en frecuencias bajas y disminuyen hacia las altas frecuencias, lo que es típico para este tipo de filtros. Los filtros de pasa altos (líneas naranjas) muestran el comportamiento opuesto, con una magnitud baja en frecuencias bajas que aumenta hacia las frecuencias altas. La transición entre las

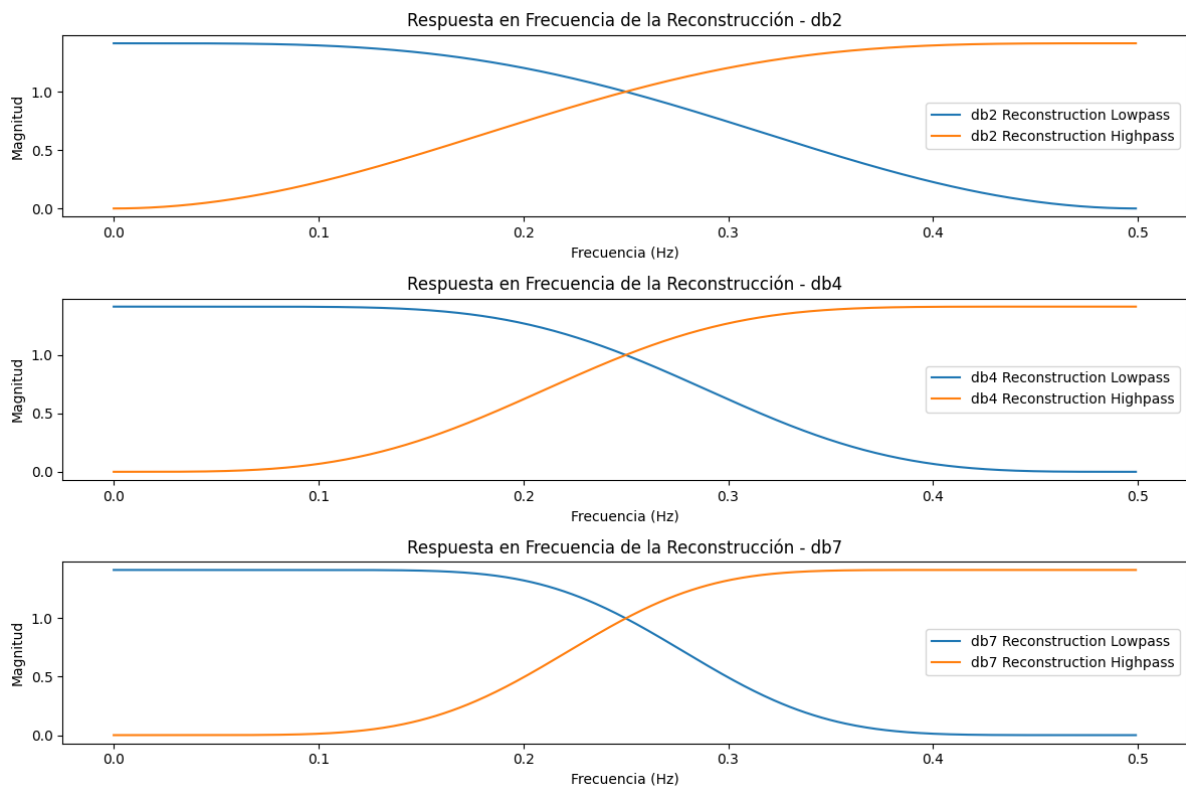


Figura 3.14: Respuesta en frecuencia de los filtros pasa bajos y pasa altos de reconstrucción utilizando diferentes versiones de la familia de wavelets Daubechies (db2, db4 y db7).

frecuencias baja y alta varía entre las wavelets, con db7 mostrando una transición más suave comparada con db2 y db4.

En la Figura 3.15 , podemos ver que en el eje horizontal muestra la frecuencia que va desde 0 hasta 0.5 Hz, esto representa la mitad del espectro de frecuencia debido al teorema de Nyquist. Mientras que en el eje vertical muestra la magnitud de la respuesta en frecuencia. Esto indica cuánto se amplifica o atenúa una determinada frecuencia por el filtro.

Algorithm 9 Análisis de Respuestas en Frecuencia de Wavelets

Require: Wavelets (ej. 'db2', 'db4', 'db7')**Ensure:** Gráficas de respuestas en frecuencia de descomposición y reconstrucción

```

1: Definir wavelets:
2: wavelets ← ['db2','db4','db7']
3: Definir nivel de descomposición level ← 1
4: Definir frecuencias para el eje x:
5: frequencies ← FFTFreq(1024)
6: Crear figuras para descomposición y reconstrucción:
7: (fig_decomposition, axs_decomposition) ← Crear subgráficas
8: (fig_reconstruction, axs_reconstruction) ← Crear subgráficas
9: for i ← 0 to len(wavelets)-1 do
10:  Obtener coeficientes de la wavelet:
11:  (dec_lo, dec_hi, rec_lo, rec_hi) ← Wavelet(wavelets[i]).filter_bank
12:  Calcular respuestas en frecuencia de descomposición:
13:  freq_response_dec_lo ← FFT(dec_lo, 1024)
14:  freq_response_dec_hi ← FFT(dec_hi, 1024)
15:  Calcular respuestas en frecuencia de reconstrucción:
16:  freq_response_rec_lo ← FFT(rec_lo, 1024)
17:  freq_response_rec_hi ← FFT(rec_hi, 1024)
18:  Graficar respuestas en frecuencia de descomposición:
19:  axs_decomposition[i].plot(frequencies[: 512], |freq_response_dec_lo[: 512]|)
20:  axs_decomposition[i].plot(frequencies[: 512], |freq_response_dec_hi[: 512]|)
21:  axs_decomposition[i].set_title(f'Respuesta en Frecuencia de la Descomposición -
    wavelets[i]')
22:  axs_decomposition[i].set_xlabel('Frecuencia (Hz)')
23:  axs_decomposition[i].set_ylabel('Magnitud')
24:  axs_decomposition[i].legend()
25:  Graficar respuestas en frecuencia de reconstrucción:
26:  axs_reconstruction[i].plot(frequencies[: 512], |freq_response_rec_lo[: 512]|)
27:  axs_reconstruction[i].plot(frequencies[: 512], |freq_response_rec_hi[: 512]|)
28:  axs_reconstruction[i].set_title(f'Respuesta en Frecuencia de la Reconstrucción - wa-
    velets[i]')
29:  axs_reconstruction[i].set_xlabel('Frecuencia (Hz)')
30:  axs_reconstruction[i].set_ylabel('Magnitud')
31:  axs_reconstruction[i].legend()
32: end for
33: Ajustar espaciado entre subplots y mostrar figuras:
34: plt.tight_layout()
35: plt.show()

```

Algorithm 10 Análisis de Respuestas en Frecuencia de Wavelets

Require: Wavelets (ej. 'db2', 'db4', 'db8')**Ensure:** Gráficas de respuestas en frecuencia de descomposición y reconstrucción

```

1: Definir wavelets:
2: wavelets ← ['db2','db4','db8']
3: Definir nivel de descomposición level ← 1
4: Definir frecuencias para el eje x:
5: frequencies ← FFTFreq(1024)
6: Crear figuras para descomposición y reconstrucción:
7: (fig_decomposition, ax_decomposition) ← Crear figura(10, 6)
8: (fig_reconstruction, ax_reconstruction) ← Crear figura(10, 6)
9: for cada wavelet en wavelets do
10:   Obtener coeficientes de la wavelet:
11:   (dec_lo, dec_hi, rec_lo, rec_hi) ← Wavelet(wavelet).filter_bank
12:   Calcular respuestas en frecuencia de descomposición:
13:   freq_response_dec_lo ← FFT(dec_lo, 1024)
14:   freq_response_dec_hi ← FFT(dec_hi, 1024)
15:   Calcular respuestas en frecuencia de reconstrucción:
16:   freq_response_rec_lo ← FFT(rec_lo, 1024)
17:   freq_response_rec_hi ← FFT(rec_hi, 1024)
18:   Graficar respuestas en frecuencia de descomposición:
19:   ax_decomposition.plot(frequencies[: 512], |freq_response_dec_lo[: 512]|)
20:   ax_decomposition.plot(frequencies[: 512], |freq_response_dec_hi[: 512]|)
21:   Graficar respuestas en frecuencia de reconstrucción:
22:   ax_reconstruction.plot(frequencies[: 512], |freq_response_rec_lo[: 512]|)
23:   ax_reconstruction.plot(frequencies[: 512], |freq_response_rec_hi[: 512]|)
24: end for
25: Configurar figura de descomposición:
26: ax_decomposition.set_title('Respuesta en Frecuencia de la Descomposición')
27: ax_decomposition.set_xlabel('Frecuencia (Hz)')
28: ax_decomposition.set_ylabel('Magnitud')
29: ax_decomposition.legend()
30: Configurar figura de reconstrucción:
31: ax_reconstruction.set_title('Respuesta en Frecuencia de la Reconstrucción')
32: ax_reconstruction.set_xlabel('Frecuencia (Hz)')
33: ax_reconstruction.set_ylabel('Magnitud')
34: ax_reconstruction.legend()
35: Mostrar figuras:
36: plt.tight_layout()
37: plt.show()

```

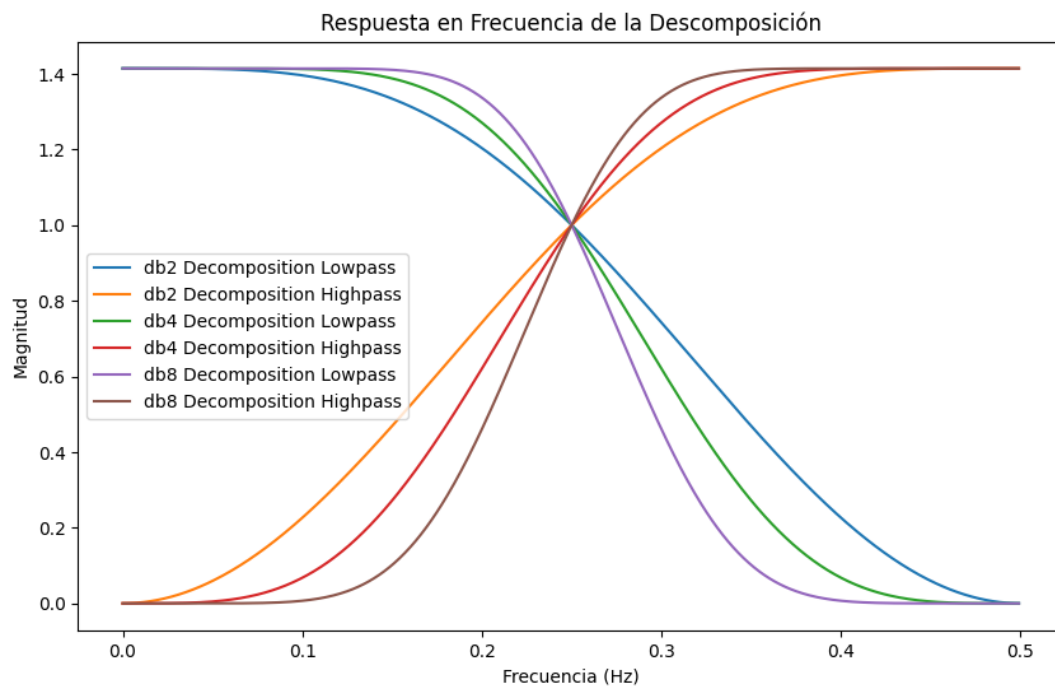


Figura 3.15: Respuesta en frecuencia de los filtros de descomposición utilizando las wavelets de Daubechies (*db2*, *db4*, y *db8*) tanto para filtros pasabajos (*Lowpass*) como para filtros pasaltos (*Highpass*).

Por tanto la Figura 3.16 proporciona una visualización clara de cómo diferentes wavelets afectan la descomposición de señales en términos de frecuencia. Las wavelets *db2*, *db4* y *db8* muestran distintas características en sus respuestas en frecuencia.

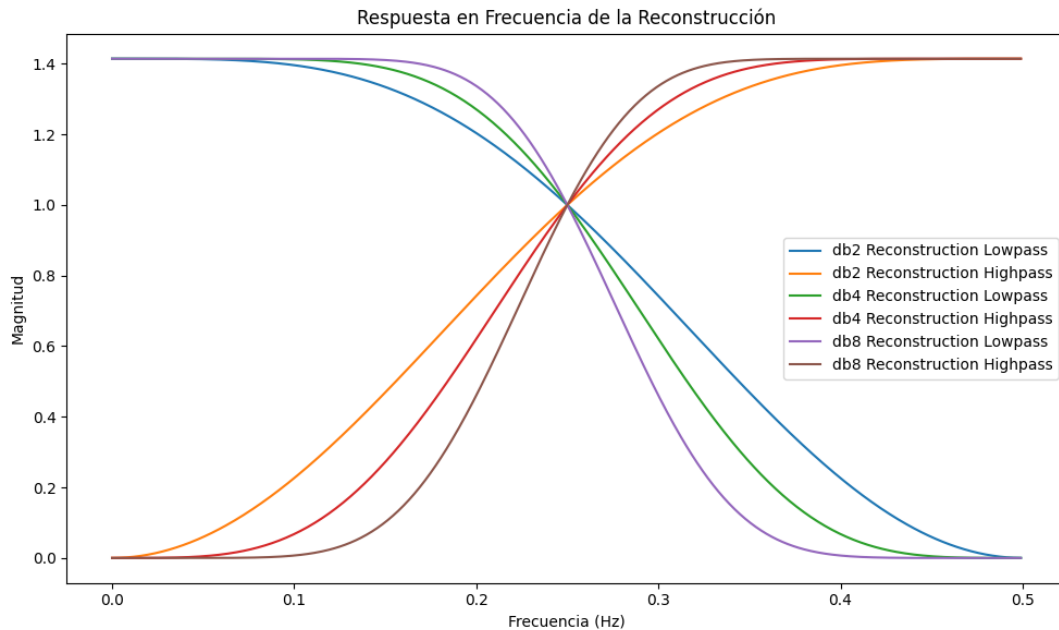


Figura 3.16: Esta gráfica muestra las curvas de magnitud para los filtros pasa-bajas (Lowpass) y pasa-altas (Highpass) pero durante el proceso de reconstrucción.

3.4. Decodificación de la emoción

Para hacer la decodificación utilizamos los datos proporcionados por el data set y les sacamos su espectrograma para poder visualizar la emoción y poder correlacionarla para posteriormente hacer lo mismo pero con nuestro código creado y poder comparar los resultados para su validación. En este caso se acotó el análisis espectral en ventanas de 4 seg, ya que el mismo dataset indica que esa es la ventana de tiempo en que se tomaron las muestras. Para la decodificación se utilizara el análisis espectral , ya que este permite analizar cómo las frecuencias cambian a lo largo del tiempo, lo que es crucial en muchas señales reales que no son estacionarias. Los histogramas, por otro lado, son útiles para analizar la distribución de los valores de la señal, pero no ofrecen información sobre la variabilidad en el dominio de la frecuencia. Para obtener los espectros de las señales utilizaremos el siguiente pseudocódigo (el código estará en anexos):

A continuación podemos observar el espectrograma de la emoción del miedo en la Figura 3.17, así mismo en la Figura 3.18 podemos ver su característica de forma estadística:

Análisis de la emoción:Miedo

En la Figura 3.17 que muestra el miedo, el cual tiende a activar frecuencias altas (beta y gamma) debido al estado de alerta y activación que genera.

Algorithm 11 Procesamiento de señal EEG y análisis de espectrogramas usando Wavelet

- 1: Cargar el archivo `.mat` desde `file_path`
 - 2: Mostrar las claves disponibles en el archivo `mat_data`
 - 3: Seleccionar la señal EEG correspondiente a la clave `'cz_eeg1'`
 - 4: `eeg_signal = cz_eeg1` aplanado
 - 5: Definir la frecuencia de muestreo `fs = 200` Hz
 - 6: Definir la duración del segmento `segment_duration = 4` segundos
 - 7: Calcular el número de muestras por segmento: `samples_per_segment = fs × segment_duration`
 - 8: **Función** `wavelet_denoising` (`signal`, `wavelet = 'db4'`, `level = 4`)
 - 9: Aplicar la transformada wavelet discreta (`pywt.wavedec`) a la señal
 - 10: Calcular el umbral de denoising usando la mediana de los coeficientes de detalle
 - 11: Aplicar el umbral a los coeficientes usando un método suave (`soft thresholding`)
 - 12: Reconstruir la señal denoised usando los coeficientes modificados
 - 13: **Retornar** la señal denoised
 - 14: Aplicar `wavelet_denoising` a la señal EEG: `eeg_signal_denoised`
 - 15: **Función** `plot_spectrogram` (`signal`, `fs`, `segment_idx`)
 - 16: Configurar la figura para el gráfico
 - 17: Definir la wavelet y los escalas (`scales`) para la transformada de wavelet
 - 18: Calcular la transformada continua de wavelet (`pywt.cwt`)
 - 19: Graficar la señal EEG en función del tiempo
 - 20: Graficar el espectrograma basado en la transformada wavelet
 - 21: Mostrar el gráfico
 - 22: Calcular el número de segmentos `num_segments =` mínimo entre 10 y el número total de segmentos
 - 23: **for** cada segmento `i` en `num_segments` **do**
 - 24: Definir el índice de inicio y fin del segmento: `start_idx`, `end_idx`
 - 25: Extraer el segmento `segment` de la señal denoised
 - 26: Aplicar `plot_spectrogram` al segmento
 - 27: **end for**
-

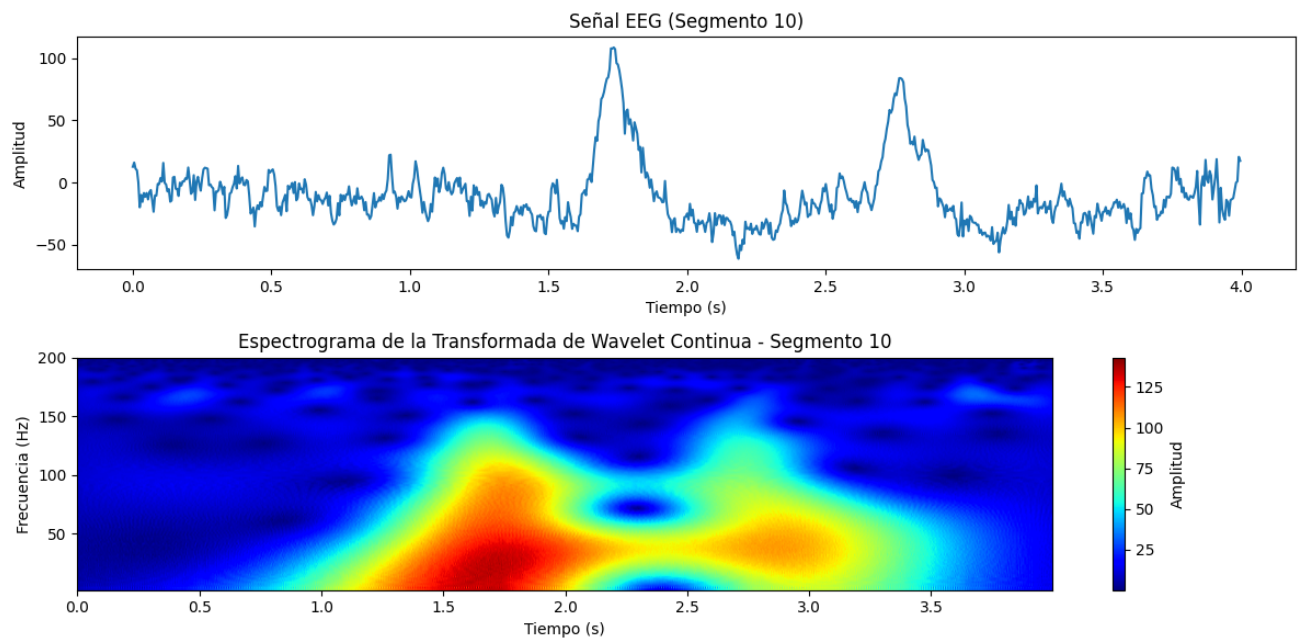


Figura 3.17: Espectrograma de la emoción de miedo

El patrón observado en el espectrograma con picos altos en este rango sugiere una emoción de activación intensa como el miedo, ya que el cerebro está en un estado de mayor excitación cuando experimenta esta emoción. Se observa un aumento notable en las frecuencias alrededor de los 40 a 100 Hz, que generalmente está en el rango beta y gamma, lo que está relacionado con emociones de mayor activación y estrés, como el miedo.

En el gráfico de la Figura 3.18 muestra las características extraídas de la señal EEG mediante la Transformada Wavelet.




Figura 3.18: Característica de la emoción del miedo

Eje X (Niveles de Coeficientes Wavelet): Cada barra representa un nivel de descomposición de la señal EEG usando la Transformada Wavelet. En esta gráfica, se han descompuesto los datos en 5 niveles (0 a 4). El nivel 0 es el nivel de detalle más bajo, que captura las variaciones más gruesas de la señal (bajas frecuencias), y a medida que aumentas los niveles, se capturan detalles más finos (frecuencias más altas). Eje Y (Energía): El eje Y muestra la energía asociada con cada nivel de descomposición. La energía es una medida de cuánta información o "contenido" tiene la señal en ese nivel de frecuencia. En este caso, la mayor parte de la energía de la señal se concentra en el nivel 0, lo que sugiere que las frecuencias más bajas dominan el segmento 10 de la señal EEG.

Análisis de la emoción: tristeza

Comenzaremos realizando un análisis del espectrograma asociado a la emoción indicada, este se muestra en la Figura 3.19.

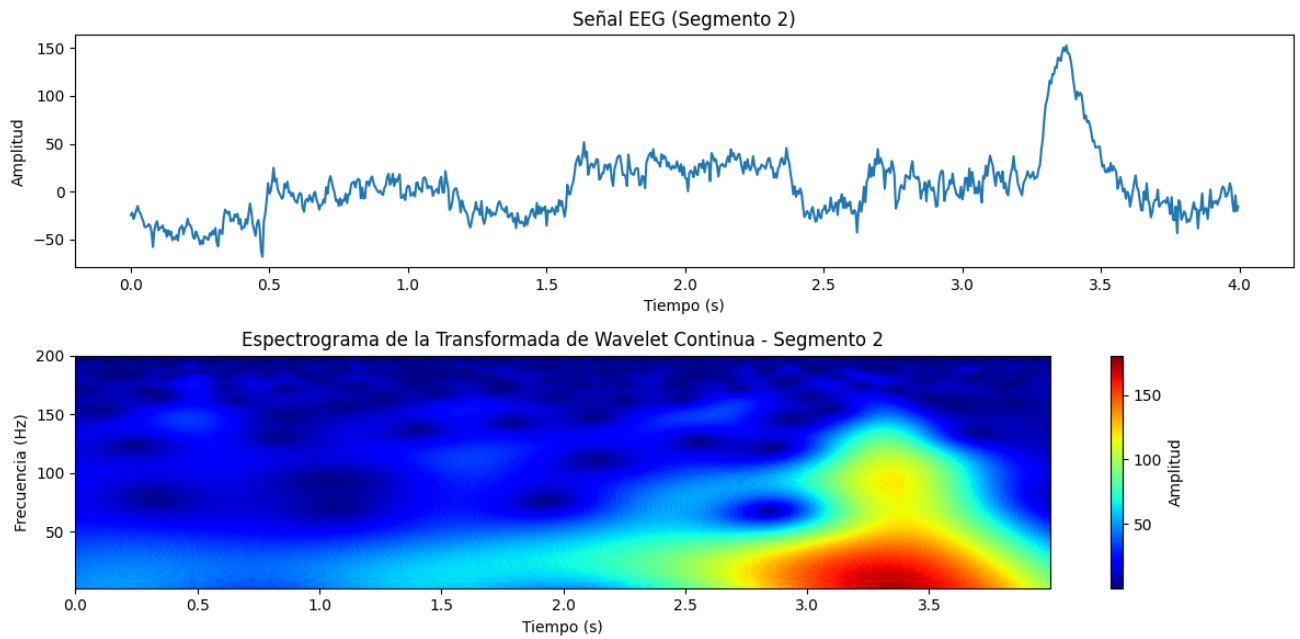


Figura 3.19: Espectrograma de la emoción de la tristeza

En el espectrograma comentado, esto es, en la Figura 3.19, se observa una activación de mediana intensidad, concentrada principalmente en las frecuencias bajas y medias (menos de 100 Hz), con un pico significativo entre los 3.0 y 3.5 segundos. La mayor parte de la energía está presente en el rango de frecuencias bajas, la tristeza, en particular, está asociada con una reducción en la actividad de alta frecuencia y una mayor presencia de frecuencias bajas, lo cual coincide con este patrón.

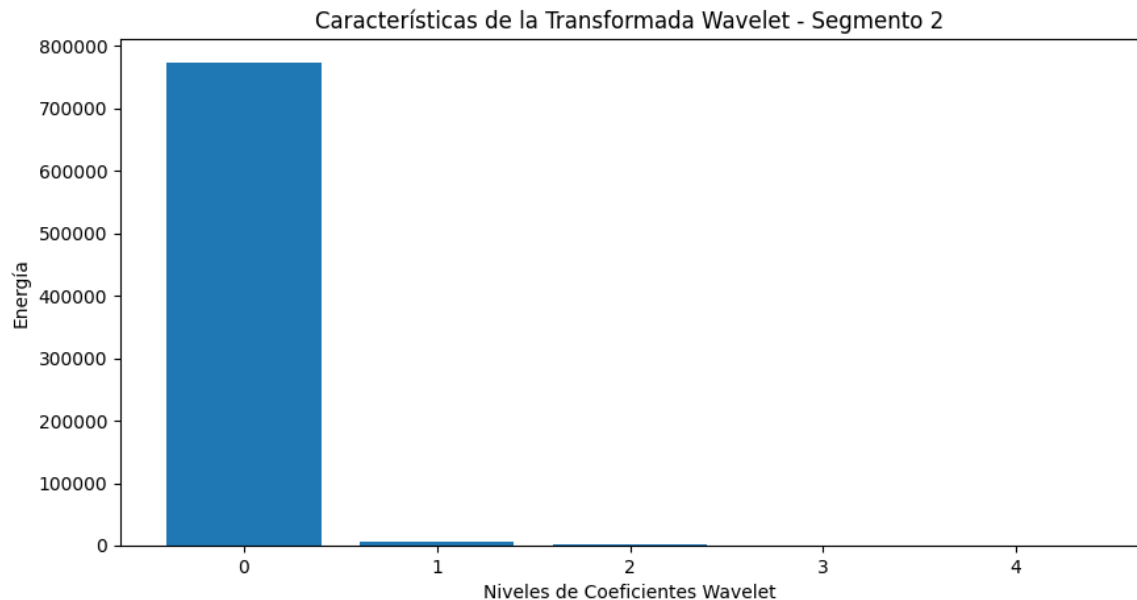


Figura 3.20: Característica de la emoción de la tristeza

La barra más alta correspondiente, se muestra en la Figura 3.20 en el primer nivel de coeficientes wavelet (nivel 0). Esto indica que la mayor parte de la energía de la señal EEG en este segmento está concentrada en las frecuencias más bajas. En los niveles superiores (1, 2, 3 y 4), las barras son significativamente más pequeñas, lo que indica que las frecuencias más altas contienen menos energía. Esto es típico en las señales EEG, donde las ondas de baja frecuencia (ondas delta y theta) suelen ser predominantes.

Análisis de la emoción: Neutral En este caso, más que determinar o realizar el análisis de una emoción, es extraer características que indiquen la no manifestación de una emoción. En la Figura 3.21 se observa el espectrograma de la emoción en un estado neutral, así como en la Figura 3.22 se muestra su espectrograma de manera estadística:




Figura 3.21: Espectrograma de la emoción en un estado neutral

Dado que las frecuencias altas no son prominentes y las medias tienen poca actividad y también que las altas amplitudes en las frecuencias bajas, especialmente Alpha y Theta, se relacionan con un estado neutral o posiblemente una relajación moderada, podemos decir que este espectrograma representa el estado calmado o neutral, sin signos evidentes de emociones intensas como el miedo o la alegría extrema.




Figura 3.22: Espectrograma de la emoción en un estado neutral

Nivel 0 (baja frecuencia): Tiene la mayor concentración de energía, superando 1 millón de unidades, como se indica en la escala vertical (1e6). Esto indica una alta dominancia de la actividad de baja frecuencia durante este segmento.

Niveles 1 a 4: Aunque la energía es mucho menor en comparación con el primer nivel, se observa una distribución ligeramente más amplia en los niveles 1, 2 y 3 que en los otros segmentos que analizaste. Esto podría indicar una mayor presencia de componentes de frecuencias medias.

Análisis de la emoción: Felicidad

En el espectrograma de la Figura 3.23 se observa lo siguiente:

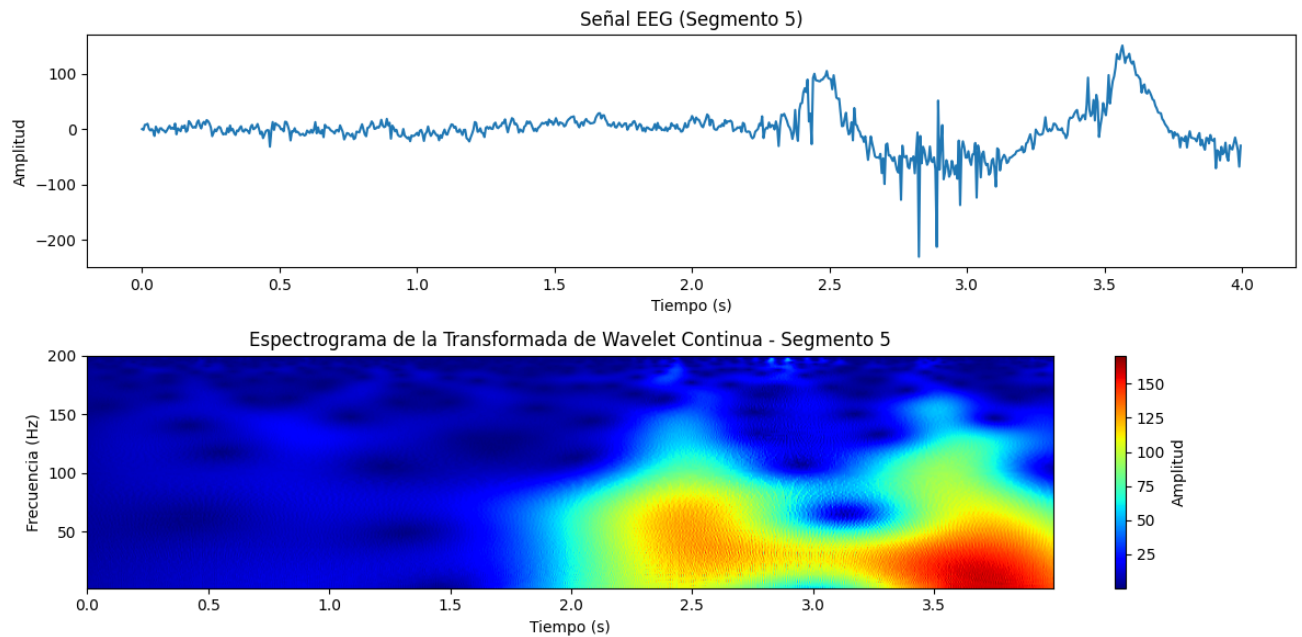


Figura 3.23: Espectrograma de la emoción en un estado de felicidad

En la Figura 3.24 se observan las características registradas por la emoción felicidad.

Hay una mayor concentración de energía en el rango bajo a medio (alrededor de 50 Hz a 100 Hz), con algunas activaciones esporádicas más intensas a partir de los 3 segundos. Dado el aumento de energía y la activación que aparece más intensamente en los segundos finales, esta señal está relacionada con la felicidad, se caracteriza por un incremento de la actividad cerebral en ciertas bandas, particularmente en la gama media-alta (felicidad). Esta activación refleja un estado de alta excitación positiva.




Figura 3.24: Característica de la emoción de felicidad

3.5. Validación del sistema

Para la validación del sistema, cargamos el data set en el código con los distintos procesos y comparamos las señales obtenidas entre el dataset y los datos. Comparamos las señales emoción por emoción. Se pueden apreciar los espectrogramas con las características obtenidas tanto procesadas como no procesadas, esto para ver la comparación, en especial en el espectrograma podemos ver la diferencias, esto debido y gracias al denoising que nos ayude a poder visualizar mejor en que momento la señal presenta picos remarcados y puntuales para la identificación de la emoción.

3.5.1. Emoción del miedo

En las Figuras 3.25 y 3.26 se pueden observar las señales sin procesar con nuestro sistema, simplemente visualizando sus características y la señal con lo cual se puede ver que la señal tiene demasiado ruido para su análisis.

Espectrograma y características sin procesado:

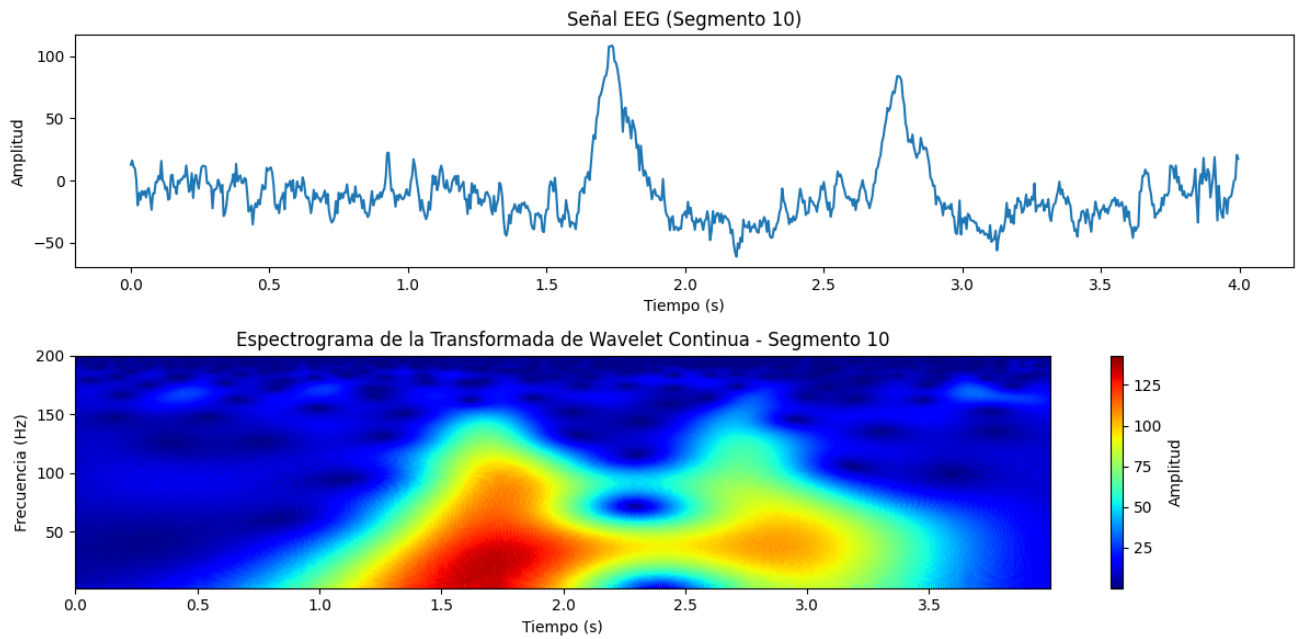


Figura 3.25: Espectrograma sin procesar de la emoción del miedo

Espectrograma y características procesado:

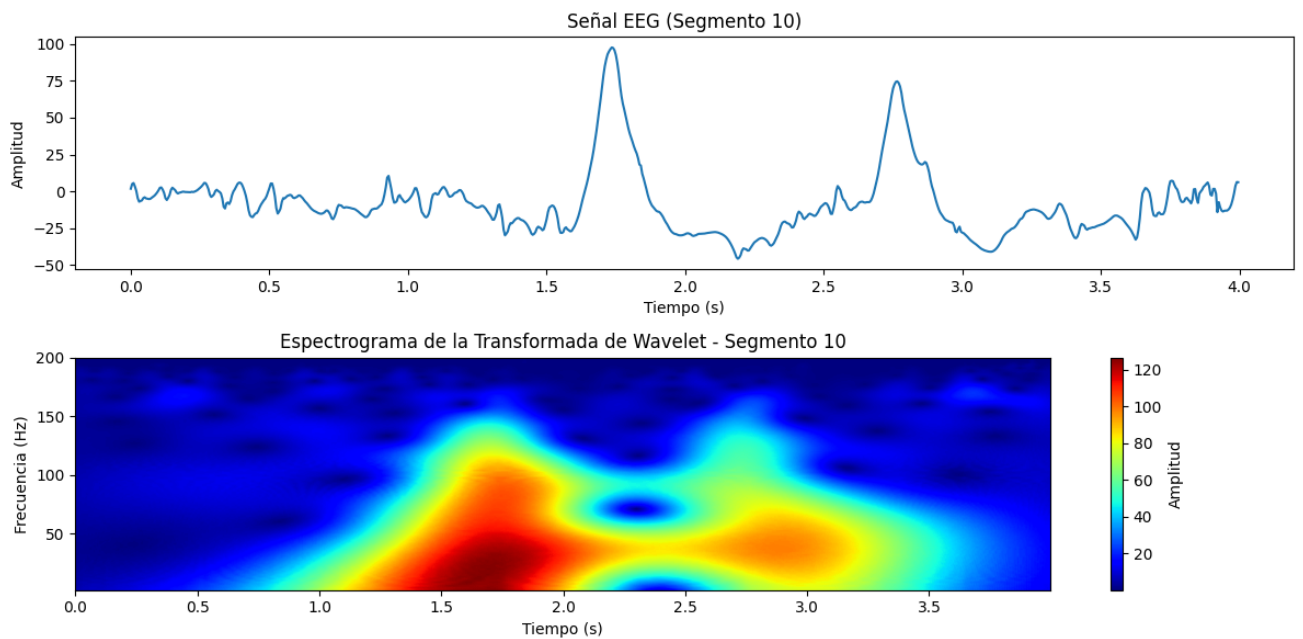


Figura 3.26: Espectrograma procesado de la emoción del miedo

3.5.2. Emoción de la tristeza

En la Figura 3.27 se puede ver una mejora muy notable en la visualización de la señal, una vez que se le ha aplicado el sistema.

Espectrograma y características sin procesamiento:




Figura 3.27: Espectrograma sin procesar de la emoción de la tristeza

De la misma manera en la Figura 3.28 observamos la figura sin algún tipo de procesamiento.

Espectrograma y características procesadas :




Figura 3.28: Espectrograma sin procesar de la emoción de la tristeza

Figura 3.29 observamos como se ve mas delineada la señal, esto es debido al procesamiento con nuestro sistema.

3.5.3. Emoción estado neutral

Espectrograma y características sin procesado:

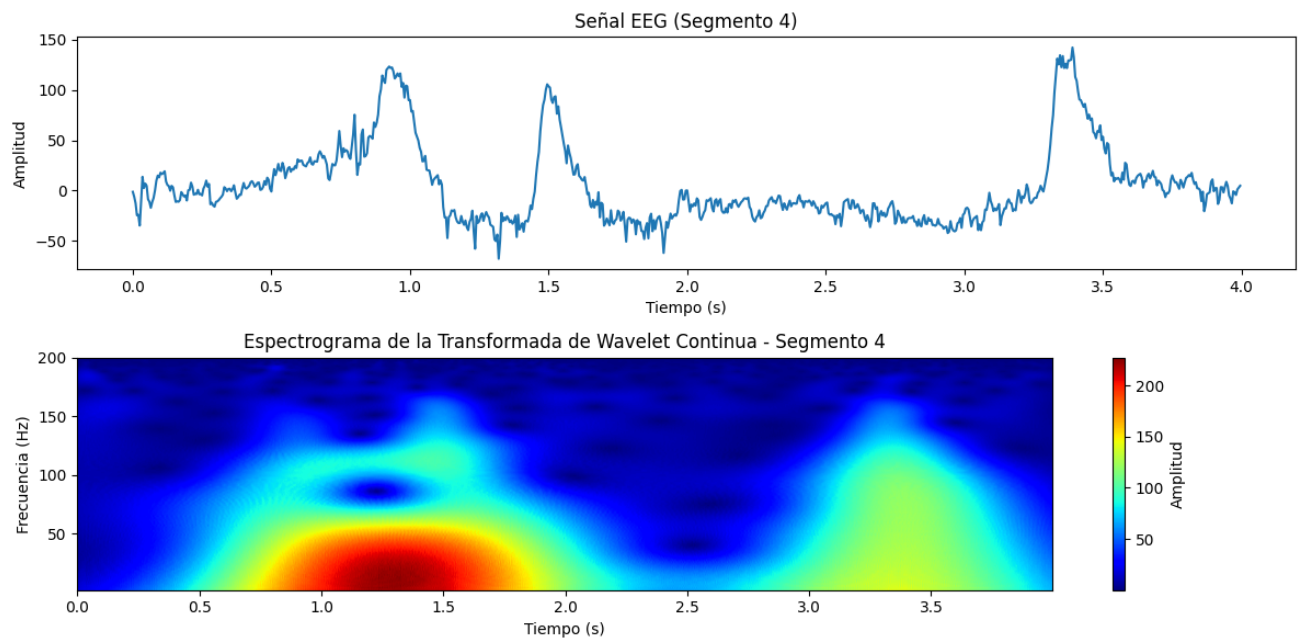


Figura 3.29: Espectrograma sin procesar de la emoción en un estado neutral

Emoción en un estado neutral sin procesar, lo cual se observa en la Figura 3.30
Espectrograma y características procesadas:

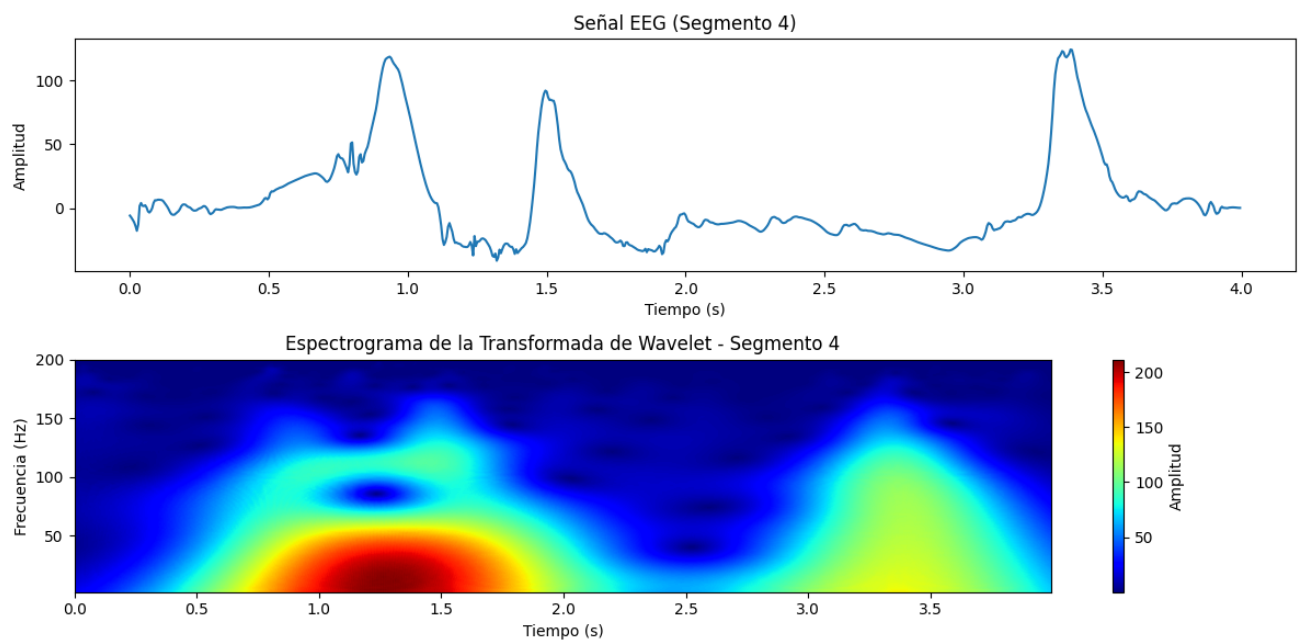


Figura 3.30: Espectrograma procesadas de la emoción en un estado neutral

En la Figura 3.31 se muestra claramente y deliadamente la señal una vez procesada.

3.5.4. Emoción de la felicidad

Espectrograma y características sin procesar:

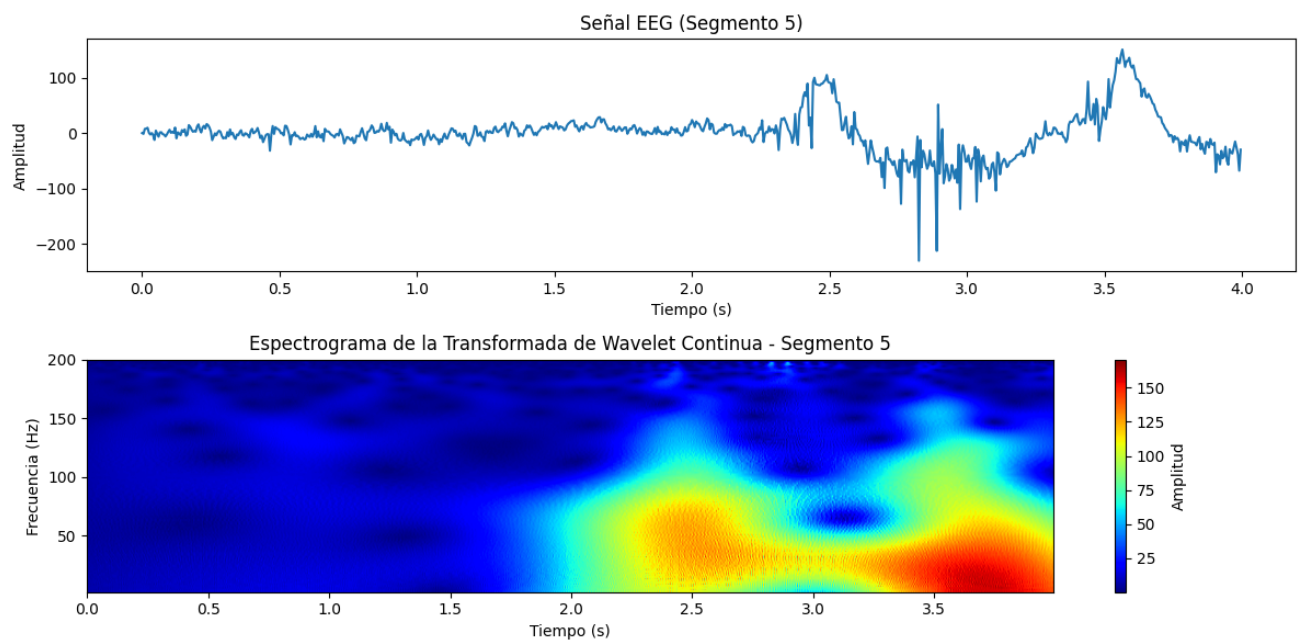


Figura 3.31: Espectrograma sin procesar de la emoción de la felicidad

Por último observamos la Figura 3.32 sin procesar.

Espectrograma y características procesadas:




Figura 3.32: Espectrograma sin procesar de la emoción de la felicidad

Observamos en la Figura 3.34 la señal procesada.

Cabe destacar que se tomaron los registros de un participante, pero usando información solo de la parte del lóbulo frontal, ya que se obtiene la información requerida, debido a que las señales que se presentan aquí en distintas frecuencias.

Capítulo 4

Resultados

Se analizaron 10 segmentos de 4 segundos cada uno, extraídos de la señal EEG registrada, utilizando la transformada Wavelet Daubechies 4, se utilizó la wavelet Daubechies 4 debido a su capacidad para capturar cambios transitorios en la señal EEG, su suavidad en la reconstrucción de la señal y su efectividad al aislar bandas de frecuencia relevantes. Esta elección permite extraer características significativas asociadas a la actividad cerebral durante estados emocionales específicos, lo que facilita la detección precisa de emociones. Se aplicó el Denoising para su filtrado y su reducción de ruido óptimo. El objetivo fue identificar la distribución de energía en diferentes niveles de frecuencia, lo que permite detectar patrones relevantes para la caracterización de estados emocionales, también para eliminar el ruido de las señales EEG, esta etapa fue fundamental para garantizar que la información extraída reflejara la actividad cerebral relacionada con las emociones, evitando interferencias provenientes de parpadeos, movimientos musculares y otras fuentes de ruido. El uso de denoising permitió que los espectrogramas mostraran patrones más claros y precisos, mejorando así la clasificación de emociones en los diferentes segmentos analizados.

En el desarrollo y durante la extracción de características se plantearon diferentes formas de como poder obtener los datos, desde obtenerlos con sujetos, hasta buscar Datos enfocados en las emociones. Se encontraron diversas problemáticas tanto de instrumentación como de adquisición de datos, sin embargo se pudieron resolver y se alcanzaron los resultados esperados, logrando procesar las señales y reducir el ruido y la fiabilidad de la señal, al final se pudieron reconocer las emociones requeridas así como la comparación de las señales del dataset a las que nosotros obtuvimos, cabe destacar que se observa una mejora notable en las señales comparadas. A continuación veremos las señales obtenidas junto con sus respectivas etiquetas asociadas a sus emociones.

Emoción del miedo:

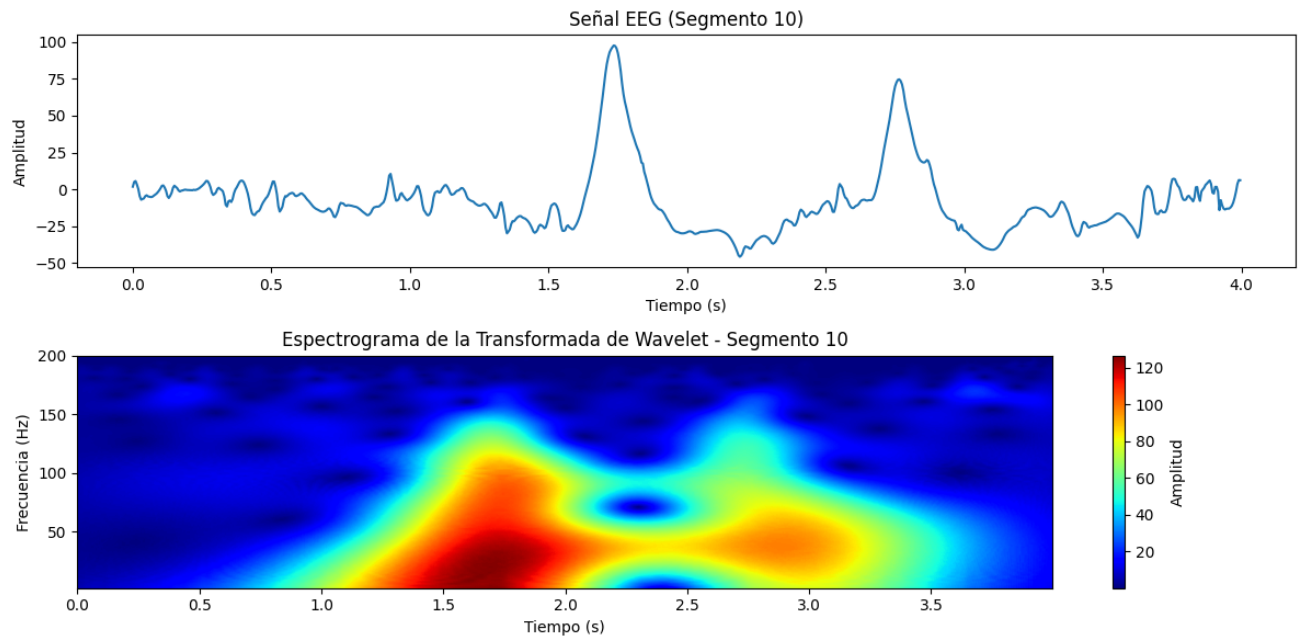


Figura 4.1: Espectrograma de la emoción de miedo

Emoción de la Tristeza:




Figura 4.2: Espectrograma de la emoción de la tristeza

Emoción estado neutral:

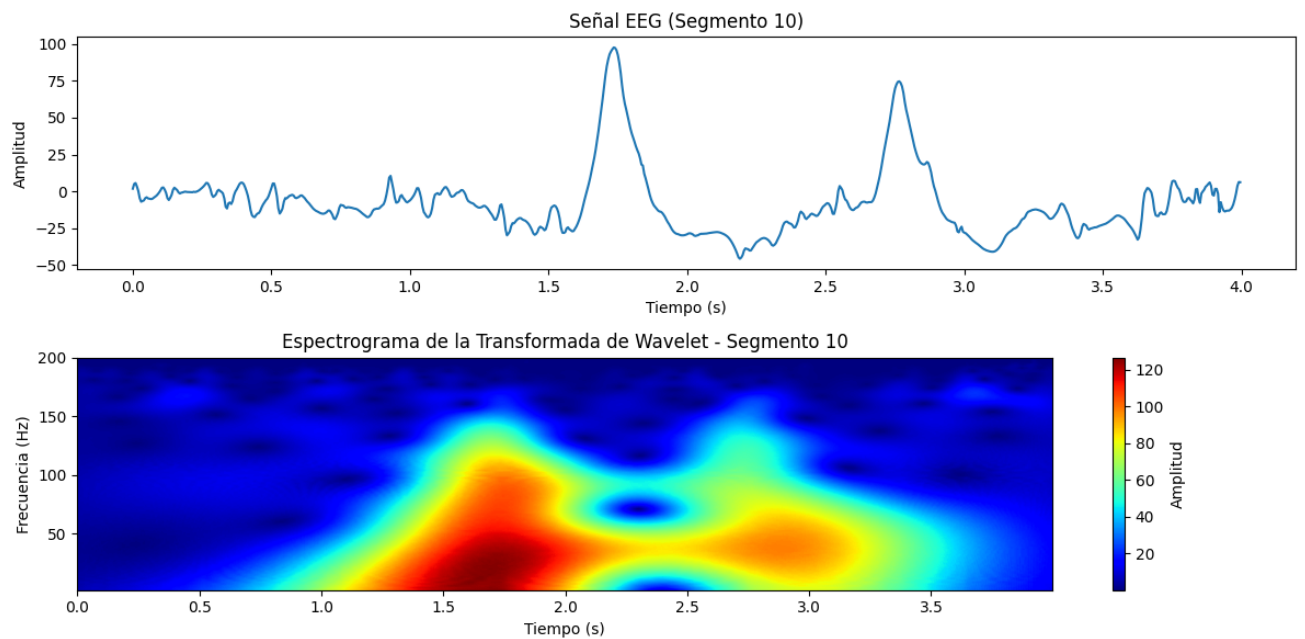


Figura 4.3: Espectrograma de la emoción en un estado neutral

Emoción de la felicidad:




Figura 4.4: Espectrograma de la emoción en un estado de felicidad

Un resultado adicional del programa fue la identificación de múltiples emociones , se

puede observar en la Figura 4.5. Esto se logró mediante la aplicación de denoising y la wavelet Daubechies 4, que permiten un filtrado por sub-bandas, facilitando un análisis más preciso. A continuación, se presenta la señal en particular, en la que se observan los efectos de este procesamiento.




Figura 4.5: Espectrograma de la emoción con doble emoción sin denoising

Espectrograma con Denoising:

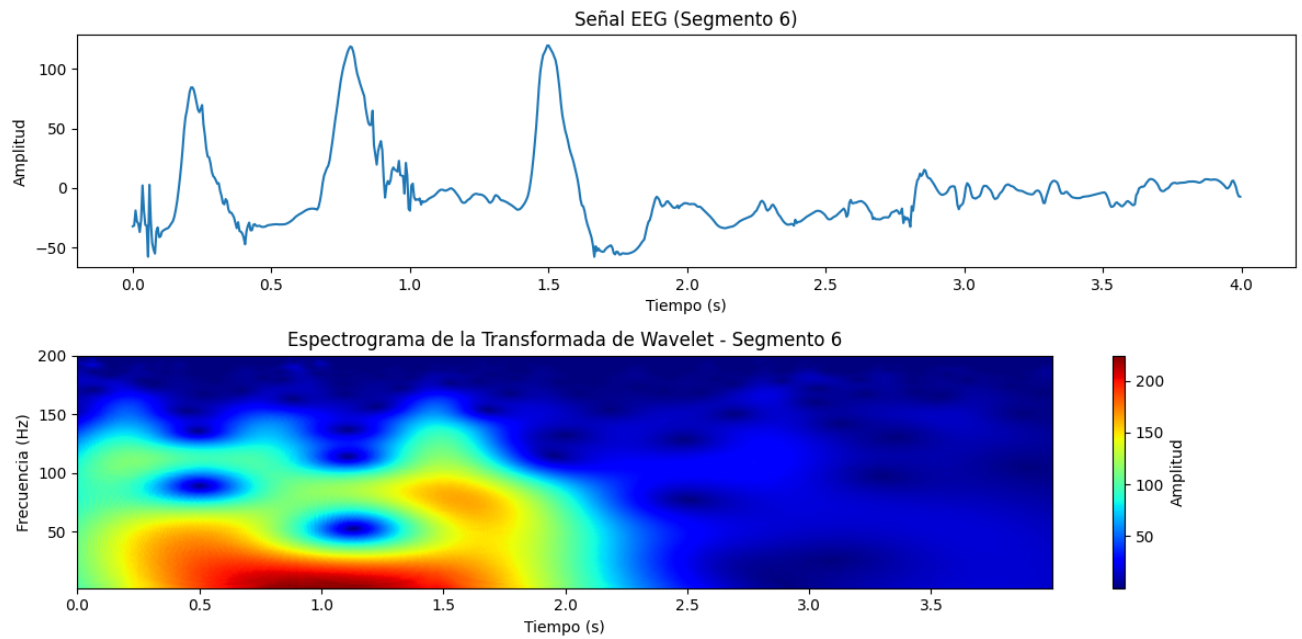


Figura 4.6: Espectrograma de la emoción con doble emoción con denoising

En la gráfica de la señal sin aplicar denoising, se observa la presencia de ruido entre los segundos 2 y 4. Sin embargo, en la señal con denoising, a partir del segundo 2 se aprecia una mayor estabilidad, lo cual podría indicar un estado neutro debido a la continuidad en el tiempo. Esto sugiere que, aunque inicialmente se percibiera como ruido, al final revela una emoción que puede tener relevancia según el contexto.

Capítulo 5

Conclusiones

El presente trabajo desarrolló un sistema de reconocimiento de emociones basado en señales EEG mediante el uso de la transformada Wavelet Daubechies 4 y técnicas de denoising. Este enfoque permitió identificar con éxito patrones característicos en las señales correspondientes a las emociones de miedo, tristeza, felicidad y estado neutral. Los resultados experimentales se detallan a continuación:

- **Filtrado y mejora en la calidad de las señales:** La técnica de denoising aplicada a las señales EEG resultó en una notable reducción de ruido generados por movimientos musculares, parpadeos y otras fuentes de interferencia. Esta limpieza permitió obtener señales más estables y precisas, esenciales para una correcta identificación emocional. La transformada Wavelet Daubechies 4 fue particularmente adecuada debido a su capacidad para analizar señales no estacionarias, como las EEG, permitiendo un óptimo filtrado que optimizó la claridad de las señales en sub-bandas específicas.
- **Identificación de emociones a través de patrones en frecuencias específicas:** Al segmentar las señales en ventanas de 4 segundos, los espectrogramas obtenidos revelaron patrones distintivos para cada emoción. Los resultados sugieren que:
 - *Tristeza y miedo:* Estas emociones presentaron mayor concentración de energía en frecuencias bajas, lo que podría correlacionarse con una actividad neuronal asociada a estados de alerta o respuestas defensivas.
 - *Felicidad:* Se observó un patrón de estabilidad en frecuencias medias, lo cual sugiere una posible relación con una activación cerebral de bajo a moderado nivel, característico de estados emocionales positivos.
 - *Estado neutral:* En esta emoción, las señales mostraron estabilidad en frecuencias medias y altas, indicando un equilibrio sin activación extrema, lo que resulta coherente con un estado emocional estable o sin perturbaciones.

- **Detección de múltiples emociones en una misma señal:** Uno de los hallazgos más destacados fue la capacidad del sistema para identificar la presencia de múltiples emociones en una misma señal. Este fenómeno fue detectado gracias al filtrado en sub-bandas, que facilitó el análisis detallado de cambios sutiles en las frecuencias. La detección de estas transiciones emocionales sugiere que el método podría ser aplicable en tiempo real, ofreciendo un medio de análisis continuo y dinámico en contextos como la psicología.

Implicaciones para Futuros Desarrollos

- **Integración de algoritmos de aprendizaje automático:**

Si bien el presente estudio demostró la eficacia de las técnicas de denoising y transformada wavelet en la detección de emociones, la precisión del sistema podría incrementarse mediante la integración de algoritmos de aprendizaje automático. Modelos como las redes neuronales profundas o los clasificadores basados en árboles de decisión podrían optimizar la identificación y clasificación de emociones en tiempo real.

- **Optimización en la detección de emociones múltiples:**

Dado que se observó la presencia de más de una emoción en una sola señal, se sugiere la exploración de modelos que puedan analizar patrones emocionales simultáneos. Esto podría mejorar la capacidad del sistema para diferenciar entre emociones mezcladas y estados transitorios.

Este trabajo demostró que es posible implementar un sistema de reconocimiento emocional confiable utilizando denoising y transformada wavelet. Las propuestas para futuros desarrollos, subrayan la importancia de estos métodos en el análisis emocional a partir de EEG.

Bibliografía

- [1] U. Rajendra Acharya, Francesco Molinari y Jasjit S. Suri. “Automated analysis of EEG signals using wavelet transform and neural network classifiers”. En: *Brain and Behavior* 15 (2005), págs. 110-125. DOI: 10.1002/brb3.123.
- [2] Abbas Saad Alatrany et al. “An explainable machine learning approach for Alzheimer’s disease classification.” En: *Scientific Reports* 14.1 (2024), págs. 1-18. ISSN: 20452322. URL: <https://bibliotecabuap.elogim.com/auth-meta/login.php?url=https%3a%2f%2fsearch.ebscohost.com%2flogin.aspx%3fdirect%3dtrue%26db%3dasn%26AN%3d175199071%26lang%3des%26site%3dehost-live%26scope%3dsite>.
- [3] Oscar Almanza-Conejo et al. “Emotion Recognition Using Electroencephalogram Signals and a 1D Local Binary Pattern for an ML-Classification-Based Approach”. En: vol. 695 LNNS. Springer Science y Business Media Deutschland GmbH, 2024, págs. 13-23. ISBN: 9789819930425. DOI: 10.1007/978-981-99-3043-2_2. URL: <https://springerlink.bibliotecabuap.elogim.com/article/10.1007/s13755-018-0048-y>.
- [4] Novick José J. Cooper Mohamed W. ElSayed Andrés. *El dulce sabor del progreso: la evolución del papel de la electroencefalografía en psiquiatría*. Abr. de 2023. URL: <https://psiquiatria.com/psiquiatria-general/el-dulce-sabor-del-progreso-la-evolucion-del-papel-de-la-electroencefalografia-en-psiquiatria/>.
- [5] Autor(es) del artículo. “Journal of Undergraduate Neuroscience Education”. En: *J Undergrad Neurosci Educ* 17.1 (2018). Fall, A10-A19. URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6312138/>.
- [6] Tara J. Brigham. “Merging Technology and Emotions: Introduction to Affective Computing”. En: *Medical Reference Services Quarterly* 36 (4 oct. de 2017), págs. 399-407. ISSN: 0276-3869. DOI: 10.1080/02763869.2017.1369289. URL: <https://www.tandfonline.com/doi/full/10.1080/02763869.2017.1369289>.
- [7] Alastair Compston. “The Berger rhythm: potential changes from the occipital lobes in man, by E.D. Adrian and B.H.C. Matthews (From the Physiological Laboratory, Cambridge). *Brain* 1934: 57; 355–385.” En: *Brain: A Journal of Neurology* 133.1 (2010), págs. 3-6. ISSN: 00068950. URL: <https://bibliotecabuap.elogim.com/>

- auth-meta/login.php?url=https%3a%2f%2fsearch.ebscohost.com%2flogin.aspx%3fdirect%3dtrue%26db%3dasn%26AN%3d51492224%26lang%3des%26site%3dehost-live%26scope%3dsite.
- [8] Britanita Enciclopedia. *Luigi Galvani*. 2021. URL: <https://www.britannica.com/biography/Luigi-Galvani>.
- [9] *EPILEPSIA A TRAVÉS DEL TIEMPO*. 2024. URL: <https://www.medicine.abbott/mx/index.html>.
- [10] R Expósito, J Rubio y M Solórzano. “Terapias aplicadas a personas con trastornos mentales”. En: *Enfermería avanzada* (2012), págs. 1-16.
- [11] Boxun Fu et al. “Conditional generative adversarial network for EEG-based emotion fine-grained estimation and visualization.” En: *Journal of Visual Communication Image Representation* 74 (2021), N.PAG. ISSN: 10473203. URL: <https://bibliotecabuap.elogim.com/auth-meta/login.php?url=https%3a%2f%2fsearch.ebscohost.com%2flogin.aspx%3fdirect%3dtrue%26db%3dasn%26AN%3d148125250%26lang%3des%26site%3dehost-live%26scope%3dsite>.
- [12] M. Ghil y C. Taricco. “Advanced spectral-analysis methods”. En: *Past and present variability of the solar-terrestrial system : measurement* (1997).
- [13] FDA-NIH Biomarker Working Group. *BEST (Biomarkers, EndpointS, and other Tools) Resource: Harmonizing biomarker terminology*. 2016. URL: <https://www.ncbi.nlm.nih.gov/books/NBK326791>.
- [14] Jisu Elsa Jacob et al. “Diagnosis of Encephalopathy Based on Energies of EEG Subbands Using Discrete Wavelet Transform and Support Vector Machine”. En: *Neurology Research International* 2018 (2018). ISSN: 20901860. DOI: 10.1155/2018/1613456. URL: <https://pubmed.ncbi.nlm.nih.gov/30057813/>.
- [15] Kranti Kamble y Joydeep Sengupta. “A comprehensive survey on emotion recognition based on electroencephalograph (EEG) signals”. En: *Multimedia Tools and Applications* 82 (18 jul. de 2023), págs. 27269-27304. ISSN: 15737721. DOI: 10.1007/s11042-023-14489-9. URL: <https://springerlink.bibliotecabuap.elogim.com/article/10.1007/s11042-023-14489-9>.
- [16] Kent M. Lee, Fernando Ferreira-Santos y Ajay B. Satpute. “Predictive processing models and affective neuroscience”. En: *Neuroscience & Biobehavioral Reviews* 131 (2021), págs. 211-228. ISSN: 0149-7634. DOI: <https://doi.org/10.1016/j.neubiorev.2021.09.009>. URL: <https://www.sciencedirect.com/science/article/pii/S0149763421003924>.
- [17] Bear M. *Kickstart-EEG-research-Ebook*. 2022. URL: https://info.tmsi.com/hubfs/Downloads/ebook/Kickstart-EEG-research-Ebook.pdf?utm_campaign=EEG&utm_medium=email&_hsenc=p2ANqtz--3IN-ceLHoVklmfwe4Zcj5TDDqzvvgm4V8mfPUsvYRY0-WZwk-qeyU0WhT-XSaKdcf2LSTjt0Lw3iQ_SUx71P0g2L5xHw&_hsmi=244440657&utm_content=244440657&utm_source=hs_automation.

- [18] Luis Carlos Mayor, Jorge Burneo y Juan Ochoa. *Manual de electroencefalografía. Handbook of Electroencephalography*. Siglo del Hombre Editores, 2013. ISBN: 9789586959469. URL: <https://bibliotecabuap.elogim.com/auth-meta/login.php?url=https%3a%2f%2fsearch.ebscohost.com%2flogin.aspx%3fdirect%3dtrue%26db%3de000xww%26AN%3d1822919%26lang%3des%26site%3ded-live>.
- [19] Christos P. Panteliadis. *Historical Overview of electroencephalography: from antiquity to the beginning of the 21st Century*. 2021. URL: <https://escientificpublishers.com/historical-overview-of-electroencephalography-from-antiquity-to-the-beginning-of-the-21st-century-JBND-03-0020>.
- [20] Roberto D Pascual-Marqui. *Low resolution electromagnetic tomography*. 2014. URL: <http://www.uzh.ch/keyinst/loreta.htm>.
- [21] Eduardo Fonseca Pedrero et al. *Tratamientos psicológicos empíricamente apoyados para adultos: una revisión selectiva TT - Evidence-Based Psychological Treatments for Adults: A Selective Review*. 2021.
- [22] Arpan Phukan y Deepak Gupta. “Deep feature extraction from EEG signals using xception model for emotion classification”. En: *Multimedia Tools and Applications* 83 (11 mar. de 2024), págs. 33445-33463. ISSN: 15737721. DOI: 10.1007/s11042-023-16941-2. URL: <https://springerlink.bibliotecabuap.elogim.com/article/10.1007/s11042-023-16941-2>.
- [23] Alejandro Piedrahíta-Carvajal et al. “Aplicación web para el análisis de emociones y atención de estudiantes”. En: *TecnoLógicas* 24 (51 2021). ISSN: 0123-7799. DOI: 10.22430/22565337.1821.
- [24] Russell A. Poldrack, Yaroslav O. Halchenko y Stephen José Hanson. “Decoding the Large-Scale Structure of Brain Function by Classifying Mental States Across Individuals”. En: *Psychological Science* 20.11 (2009). PMID: 19883493, págs. 1364-1372. DOI: 10.1111/j.1467-9280.2009.02460.x. eprint: <https://doi.org/10.1111/j.1467-9280.2009.02460.x>. URL: <https://doi.org/10.1111/j.1467-9280.2009.02460.x>.
- [25] Philipp S. Reif, Adam Strzelczyk y Felix Rosenow. *The history of invasive EEG evaluation in epilepsy patients*. Oct. de 2016. DOI: 10.1016/j.seizure.2016.04.006.
- [26] Facundo Ruffinatto et al. “Determinantes psicosociales, adherencia a políticas de salud y búsqueda de apoyo en adultos de la ciudad de Córdoba, Argentina, en contexto de pandemia”. En: *Vertex Revista Argentina de Psiquiatría* 34.159, ene.-mar. (Abr. de 2023), págs. 6-17. DOI: 10.53680/vertex.v34i159.360. URL: <https://revistavertex.com.ar/ojs/index.php/vertex/article/view/360>.

- [27] Ayan Seal et al. “An EEG Database and Its Initial Benchmark Emotion Classification Performance”. En: *Computational and Mathematical Methods in Medicine* 2020 (2020). ISSN: 17486718. DOI: 10.1155/2020/8303465. URL: <https://pubmed.ncbi.nlm.nih.gov/32831902/>.
- [28] José Ramiro Zapata. *Las seis emociones emociones básicas de paul ekman*. 2020. URL: <https://www.slideshare.net/slideshow/las-seis-emociones-emociones-basicas-de-paul-ekman/238996071>.
- [29] Jian Zhao et al. “Cognitive psychology-based artificial intelligence review”. En: *Frontiers in Neuroscience* 16 (oct. de 2022). ISSN: 1662453X. DOI: 10.3389/fnins.2022.1024316. URL: <https://pubmed.ncbi.nlm.nih.gov/36278021/>.
- [30] Wei Long Zheng et al. “EmotionMeter: A Multimodal Framework for Recognizing Human Emotions”. En: *IEEE Transactions on Cybernetics* 49 (3 mar. de 2019), págs. 1110-1122. ISSN: 21682267. DOI: 10.1109/TCYB.2018.2797176.
- [31] Jian Zhou et al. “An EEG emotion recognition method based on transfer learning and echo state network for HilCPS.” En: *Microprocessors ; Microsystems* 87 (2021), N.PAG. ISSN: 01419331. URL: <https://bibliotecabuap.elogim.com/auth-meta/login.php?url=https%3a%2f%2fsearch.ebscohost.com%2flogin.aspx%3fdirect%3dtrue%26db%3dasn%26AN%3d154013589%26lang%3des%26site%3dehost-live%26scope%3dsite>.

Anexos

`from scipy.io import loadmat` : La biblioteca `scipy.io` es parte de SciPy (Scientific Python) y proporciona funciones para trabajar con archivos de entrada/salida. En particular, la función `loadmat` dentro de `scipy.io` es utilizada para cargar archivos MATLAB `.mat`.

`numpy`: Para trabajar con arrays y realizar operaciones matemáticas y estadísticas, se utiliza para apoderar de manera visual y poder gráficas las variables contenidas.

`matplotlib.pyplot`: La utilizamos para crear gráficos y visualizaciones de datos.

Estas tres bibliotecas juntas son muy poderosas para la manipulación, análisis y visualización de datos científicos en Python.

`import pywt`: Permite utilizar las funcionalidades de PyWavelets, una biblioteca que proporciona herramientas para trabajar con transformadas wavelet, tanto para análisis como para procesamiento de señales.

`import pandas as pd`: `pandas` es una biblioteca esencial en Python para la manipulación y el análisis de datos. Sus principales características son la estructura de datos flexibles series Unidimensionales, como una lista. `DataFrames` bidimensionales, como una tabla en una base de datos o una hoja de cálculo de Excel y paneles, los cuales son estructuras de datos tridimensionales.

Preparación de `dataSet`:

```
from scipy.io import loadmat
import numpy as np
import matplotlib.pyplot as plt
import pywt
file_path = r"C:\Users\LUISSALOMONLOPEZ\Desktop\eeg_raw_data\1\sujeto1"
mat_data = loadmat(file_path)
```

Código:

```
import numpy as np
import matplotlib.pyplot as plt
import pywt
from scipy.io import loadmat
import matplotlib
matplotlib.use('TkAgg') # Usa TkAgg como backend interactivo

# Cargar el archivo .mat y mostrar las claves disponibles
file_path = r"C:\Users\LUISSALOMONLOPEZ\Desktop\eg_raw_data\1\sujeto1.mat"
mat_data = loadmat(file_path)

# Mostrar todas las claves para inspeccionar el contenido
print("Claves disponibles en el archivo:", mat_data.keys())

# Suponiendo que la clave correcta para los datos EEG es 'cz_eeg1'
eeg_signal = mat_data['cz_eeg1'].flatten()

# Frecuencia de muestreo
fs = 200 # Frecuencia de muestreo correcta de tu dataset
segment_duration = 4 # Duración de cada segmento en segundos
samples_per_segment = fs * segment_duration # Muestras por segmento (800 muestras p

# Función para calcular y graficar el espectrograma de un segmento
def plot_spectrogram(signal, fs, segment_idx):
    plt.figure(figsize=(12, 6))

    wavelet = 'cmor1.5-1.0'
    scales = np.arange(1, 128)

    # Calcular la Transformada de Wavelet
    coefficients, frequencies = pywt.cwt(signal, scales, wavelet, sampling_period=1/

    # Graficar la señal original
    t = np.arange(len(signal)) / fs
    plt.subplot(2, 1, 1)
    plt.plot(t, signal)
    plt.title(f'Señal EEG (Segmento {segment_idx + 1})')
    plt.xlabel('Tiempo (s)')
    plt.ylabel('Amplitud')

    # Graficar el espectrograma
    plt.subplot(2, 1, 2)
```

```

plt.imshow(np.abs(coefficients), extent=[0, t[-1], frequencies.min(), frequencies.max()])
plt.title(f'Espectrograma de la Transformada de Wavelet Continua - Segmento {segment_idx}')
plt.xlabel('Tiempo (s)')
plt.ylabel('Frecuencia (Hz)')
plt.colorbar(label='Amplitud')

plt.tight_layout()
plt.show()

# Función para extraer características de la señal usando la Transformada Wavelet
def extract_wavelet_features(signal, wavelet='db1', level=4):
    coeffs = pywt.wavedec(signal, wavelet, level=level)
    features = [np.sum(np.square(c)) for c in coeffs] # Energía de cada nivel de coeficientes
    return features

# Función para graficar las características extraídas de cada segmento
def plot_features(features, segment_idx):
    plt.figure(figsize=(10, 5))
    plt.bar(range(len(features)), features)
    plt.title(f'Características de la Transformada Wavelet - Segmento {segment_idx}')
    plt.xlabel('Niveles de Coeficientes Wavelet')
    plt.ylabel('Energía')
    plt.show()

# Segmentar la señal y calcular el espectrograma para solo 10 segmentos de 4 segundos
num_segments = min(10, len(eeg_signal) // samples_per_segment) # Limitar a 10 segmentos
for i in range(num_segments):
    start_idx = i * samples_per_segment
    end_idx = start_idx + samples_per_segment
    segment = eeg_signal[start_idx:end_idx]

    # Mostrar espectrograma del segmento
    plot_spectrogram(segment, fs, i)

    # Extraer características del segmento
    segment_features = extract_wavelet_features(segment)
    print(f"Características del Segmento {i + 1}: {segment_features}")

    # Graficar las características del segmento
    plot_features(segment_features, i)

```