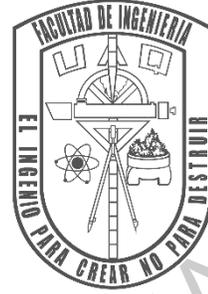


**UNIVERSIDAD AUTÓNOMA DE
QUERÉTARO
FACULTAD DE INGENIERÍA
CAMPUS AEROPUERTO**



**Detección del movimiento motor imaginario de extremidades en
señales de EEG usando medidas no lineales y algoritmos de
inteligencia artificial.**

TESIS

Como parte de los requisitos para obtener el título de

INGENIERO BIOMÉDICO

Línea Terminal

BIOSEÑALES Y BIOINSTRUMENTACIÓN

Presenta

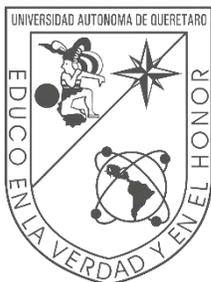
Luis Fernando Xicotencatl López Lazo

Directores

Dr. Carlos Andrés Pérez Ramírez

Dr. Juan Pablo Amézquita Sánchez

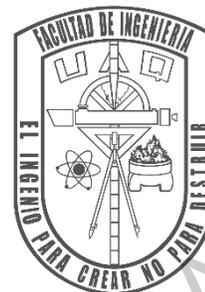
Santiago de Querétaro, Querétaro, Mayo de 2021.



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Ingeniería Biomédica



“Detección del movimiento motor imaginario de extremidades en señales de EEG usando medidas no lineales y algoritmos de inteligencia artificial.”

Tesis

Que como parte de los requisitos para obtener el título de Ingeniero Biomédico.

Presenta:

Luis Fernando Xicotencatl López Lazo

Dirigido por:

Dr. Carlos Andrés Pérez Ramírez

Dr. Juan Pablo Amézquita Sánchez

Dr. Carlos Andrés Pérez Ramírez

Presidente

Dr. Juan Pablo Amézquita Sánchez

Secretario

Dr. Martín Valtierra Rodríguez

Vocal

Ing. Eduardo Martínez Segoviano

Suplente

Firma

Firma

Firma

Firma

Centro Universitario
Querétaro, Qro.
Mayo, 2021

Resumen

Las señales de electroencefalograma (EEG) son comúnmente empleadas debido a la gran cantidad de información que contiene, así como a las aplicaciones que se les puede dar: desde el diagnóstico de enfermedades hasta su interpretación para su empleo en diferentes sistemas. Un ejemplo del punto anterior es el caso de las señales de movimiento motor imaginario (MI) que, gracias a sus características de origen, son las preferidas para ser empleadas en interfaces cerebro computadora (BCI), ya que con ellas puede realizarse el control y manipulación de prótesis y ortesis, por mencionar el ejemplo más evidente.

Este trabajo de tesis propone una metodología para la clasificación de dichas señales empleando algoritmos de moderada carga computacional, sin que ello implique perder exactitud en el proceso (comparada con otras metodologías contemporáneas). De esta manera, este trabajo propone las bases de un trabajo futuro para el desarrollo de BCIs. En particular, se trabajaron señales de MI de mano derecha y pierna izquierda provenientes de una base de datos de 11 sujetos de prueba; de esta base de datos se tomaron las señales adquiridas del electrodo C3 y C4 (en el área de la corteza motora). A dichas señales se las descompuso en tiempo-frecuencia con la transformada wavelet por paquetes (WPT), posteriormente, se le extrajeron características con diferentes métodos para comparar su efectividad. Entre los métodos comparados, se encuentran métodos de dimensión fractal como lo son el algoritmo de Katz, el algoritmo de Higuchi, el algoritmo de conteo de cajas y el algoritmo de Sevcik. Así mismo se compararon métodos de entropías como lo son la entropía de Shannon, la entropía de aproximación y la entropía de permutación. Empleando el método de análisis de varianza (ANOVA) no paramétrico, se determinó el método de dimensión fractal de Higuchi como el mejor método de extracción de características. Haciendo uso de una red neuronal multicapa con 20 neuronas en la capa oculta se clasificaron los datos previamente adquiridos, obteniendo una exactitud del 91.7% clasificando movimiento de pierna izquierda y mano derecha.

Palabras clave: procesamiento de bioseñales, EEG, movimiento motor imaginario, transformada wavelet por paquetes, dimensión fractal, entropía, ANOVA no paramétrico, redes neuronales.

Dedicatoria

A mi familia

A mis padres, Leticia y Jesús

A mi hermana, Mariana

A mi hermano, Erick

Dirección General de Bibliotecas UAQ

Agradecimientos

A mis padres, Leticia y Jesús, por apoyarme incondicionalmente a lo largo de todo este camino. Porque sin ellos no habría logrado nada de esto, los amo con todo mi ser. Gracias totales.

A mi hermano, Erick y a mi hermana, Mariana, por siempre recordarme de lo que soy capaz y nunca dejar de creer en mí, por ser mi ejemplo a seguir.

A mis padrinos, Rosa y Rogelio, por quererme como a un hijo y estar ahí siempre.

A mis profesores, que me formaron desde mi infancia a ser una persona de ciencia, Araceli, Juan, Pablo, Fernando.

Al Dr. Carlos Andrés Pérez Ramírez, por guiarme a través de esta tesis, darme de su tiempo y llenarme de conocimientos para poder concluir un trabajo como este.

Al Dr. Juan Pablo Amézquita Sánchez, al Dr. Martín Valtierra Rodríguez y al Ing. Eduardo Martínez Segoviano por sus valiosos comentarios y su atención. Por ser parte de este trabajo y apoyarme en el camino.

A los excelentes profesores de los cuales tuve la fortuna de aprender en mi carrera universitaria, gracias por compartirme su sabiduría y darme las herramientas necesarias para ser un profesional en el área.

Al Dr. Erick, por darme la oportunidad de trabajar a su lado, por todas las enseñanzas y consejos que necesitaba en el momento justo.

A mis mejores amigos Sofy y Rafa, por echarme porras todo el tiempo y por estar ahí durante todo el camino.

Al grupo 42, por ser mi segunda familia por más de 4 años, por ser el mejor grupo que pude haber pedido, por darme amistades que me van a durar para toda la vida.

A todos ustedes, Gracias.

Dirección General de Bibliotecas UAQ

ÍNDICE

1. CAPÍTULO 1 Introducción.....	1
1.1. Introducción.....	1
1.2. Antecedentes.....	2
1.3. Justificación.....	6
1.4. Descripción del problema.....	7
1.5. Hipótesis y objetivos	7
1.5.1. Hipótesis.....	7
1.5.2. Objetivo general.....	8
1.5.3. Objetivos particulares.....	8
1.6. Planteamiento general del problema.....	8
2. CAPÍTULO 2 Fundamentación Teórica	10
2.1. Señales EEG	10
2.1.1. Adquisición de señales EEG	11
2.1.2. Movimiento Motor Imaginario.....	13
2.2. Herramientas de descomposición de señales en tiempo-frecuencia.....	14
2.2.1. Transformada Wavelet	14
2.2.1.1. Transformada Wavelet por Paquetes.....	16
2.3. Características no lineales	18
2.3.1. Fractales	18
2.3.1.1. Box Counting.....	19
2.3.1.2. Katz	19
2.3.1.3. Higuchi.....	20
2.3.1.4. Sevcik.....	21
2.3.2. Entropías.....	21
2.3.2.1. Shannon.....	22
2.3.2.2. Permutación.....	22
2.3.2.3. Aproximación.....	23
2.4. ANOVA.....	24
2.4.1. ANOVA no Paramétrico	24
2.4.2. Valor-P	25
2.5. Redes Neuronales	26
2.5.1. Arquitectura y topología.....	26

2.5.2.	Algoritmo de entrenamiento.....	28
2.5.2.1.	Aprendizaje supervisado	28
3.	CAPÍTULO 3 Metodología.....	31
3.1.	Metodología propuesta	31
3.2.	Descripción de la base de datos empleada.....	33
3.2.1.	Participantes y procedimientos.....	33
3.2.2.	Adquisición de los datos	33
3.2.3.	Interacciones y paradigmas	34
3.3.	Validación de la metodología usando señales sintéticas	35
3.3.1.	Validación de la Transformada Wavelet por Paquetes.....	35
3.3.2.	Validación de Dimensión Fractal y Entropía	39
4.	CAPÍTULO 4 Experimentación y Resultados	41
4.1.	Resultados obtenidos	41
4.2.	Discusión de resultados	51
5.	CAPÍTULO 5 Conclusiones y Prospectivas	54
5.1.	Conclusiones.....	54
5.2.	Prospectivas	55
6.	Referencias Bibliográficas	56

Dirección General de Bibliotecas UAQ

CAPÍTULO 1

Introducción

1.1. Introducción

La discapacidad se clasifica como un fenómeno complejo que de manera general abarca: las deficiencias, que son problemas que afectan a la estructura o función corporal; las limitaciones, que dificultan la ejecución de acciones y tareas; y las restricciones, que son problemas para participar en situaciones vitales. Globalmente, más de mil millones de personas viven con alguna discapacidad; de estas, aproximadamente 200 millones presentan dificultades considerables en su funcionamiento. En México, de acuerdo con el Instituto Nacional de Estadística y Geografía (INEGI), tan sólo en 2014, la cantidad de personas con discapacidad representó el 6% de toda la población, lo que significa que alrededor de 7.1 millones de habitantes padecen de alguna discapacidad; de éstos, aproximadamente 64.1% con discapacidad motora del tren inferior y 33% con discapacidad motora del tren superior (INEGI, 2017).

Este problema es un motivo de preocupación ya que, en años futuros, la incidencia de este será aún mayor debido al envejecimiento de la población. Por esto, la Organización Mundial de la Salud (OMS) ha propuesto abordar dicha problemática desde la adaptación del ambiente hasta la rehabilitación y acondicionamiento del sujeto para su buen desempeño en su entorno (OIT et al., 2005). Hablando desde el extremo de la rehabilitación y acondicionamiento del sujeto, el movimiento motor imaginario (MI, por su acrónimo en inglés, Motor Imagery) ha sido empleado a lo largo de los años como un método de terapia, así como para desarrollar interfaces cerebro – computadora (BCI, por su acrónimo en inglés, Brain-Computer Interface) (Schalk et al., 2004). El MI se define como un estado mental dinámico durante el cual la representación de cierto movimiento o acto es ejecutada en el pensamiento sin ninguna salida real de movimiento (MacIntyre et al., 2018). Por consiguiente, el MI es empleado como una terapia, promoviendo la mejora de los sentidos (Cooper, 2013), aliviando dolor (Williams & Guarino, 2018), mejorando la organización

cortical y activando neuronas motoras (Gustitus, 2017), así como induciendo la excitabilidad cortico espinal (MacIntyre et al., 2018). En este sentido, diversos estudios han sido desarrollados para, aprovechado este estado mental, adquirir señales de electroencefalografía (EEG) a fin de ser procesadas y clasificadas, lo que puede generar estrategias de ayuda para personas con discapacidades, o bien, para controlar algún sistema de actuadores. Un ejemplo de las aplicaciones antes mencionadas es la implementación de una BCI para diferenciar el MI característico del movimiento de la mano y el MI del pie usando la señal de EEG (Gandhi, 2015).

Así bien, una buena clasificación y caracterización de las señales de EEG de esta índole es clave para poder tener una buena respuesta por parte del sistema de actuadores o de la BCI implementada; y de este modo, poder darles a personas con cierto tipo de discapacidad, las herramientas necesarias para poder reincorporarse a la sociedad de una mejor manera.

1.2. Antecedentes

En los últimos años, el MI ha ganado popularidad debido a su potencial para generar sistemas de movimiento de articulaciones que el usuario pueda manipular con el pensamiento. Con esto, se abre pauta para usar dicho fenómeno en la asistencia de personas con discapacidad e incluso, para poder ser aplicado en otros ámbitos, desde telemedicina y hasta la industria.

A lo largo de los años se han propuesto diversas técnicas de procesamiento/clasificación de señales EEG enfocadas a MI. Por ejemplo, Liu et al. usa el método de Grassberger–Procaccia y Higuchi para estimar la dimensión fractal (FD por su acrónimo en inglés, Fractal Dimension). En esta investigación, además, complementando la FD, se propuso una estrategia de selección basada en la matriz de información de Fisher para determinar automáticamente qué canales de EEG aportaban la mejor característica (Liu et al., 2017). Aunque este método mostró buenos resultados, posteriormente, investigadores de la universidad de Monash, Malasia, concluyeron que el método de FD es de utilidad cuando se trata de pocos movimientos que generan valores bien diferenciados, ya que movimientos simples dan como resultado alteraciones geométricas leves, generando valores de fractalidad muy similares, con diferencias imperceptibles (Namazi & Ala, 2019). En otros estudios, se

ha abordado la extracción de características de otras maneras, entre ellas, se encuentra la extracción de características por medio de los patrones espaciales comunes (CSP, por su acrónimo en inglés, Common Spatial Pattern), aunado a un análisis discriminatorio lineal (LDA, por su acrónimo en inglés, Linear Discriminant Analysis) que investigadores de Pakistán pusieron a prueba. El objetivo de esta metodología es la detección de los movimientos de la mano izquierda (MIz), mano derecha (MD) y en estado de reposo (ER). Se encontró que, con este método, se obtiene una exactitud del 60.61% (Khan et al., 2019).

A partir a los resultados poco favorables de diferentes investigadores, se optó por hacer uso de redes neuronales convolucionales (CNN, por su acrónimo en inglés, Convolutional Neural Network). Estas son similares a las redes neuronales, pero difieren estructuralmente (Teuwen & Moriakov, 2020), ya que están diseñadas para hacer análisis de texturas en imágenes, detectando patrones en cualquier lugar de una imagen (Andrearczyk & Whelan, 2017). Las CNN consisten en capas convolucionales y capas de pooling intercaladas entre sí (Mahmood et al., 2017). Las capas convolucionales se encargan de detectar características de textura, así como otras características no lineales complejas, mientras que las capas de pooling se encargan de reducir las características encontradas en el punto previo, para su rápido procesado (Davies, 2018). Dicho método de clasificación mostró mejores resultados que los métodos anteriores en aplicaciones tales como: el diagnóstico de depresión en señales de EEG (Acharya et al., 2018), detección de infarto al miocardio (Acharya et al., 2017), clasificación de características humanas como las proveídas por fotoplestimografía (Siam et al., 2021). Haciendo uso de una CNN, un grupo de investigadores de la universidad de King Saud, Arabia Saudita, con el fin de clasificar MI de MD, MIz y pies, seleccionaron de manera aleatoria 8 sujetos para entrenar la red neuronal (RN) y reservaron otro para la prueba de esta; esto de manera supervisada. Además, se hizo uso de diversos niveles de pooling para la reducción de parámetros y se realizó una conexión completa entre capas. Se llegó a una exactitud del 74.50% de acuerdo a la matriz de confusión (Amin et al., 2019). Es importante notar que los autores concluyen que una estrategia efectiva de detección de movimientos es la fusión de diferentes características y técnicas, así como cortar las señales de entrada de cada sujeto de prueba por la mitad para tener el doble de información para poder entrenar la CNN o bien, utilizar múltiples CNN que a la salida concatenen sus resultados para generar un clasificador basado en algún otro algoritmo que sea efectivo para

diferenciar entre los diferentes movimientos. Debe resaltarse que, según los resultados presentados en diversos trabajos, se concluye que hay bandas únicas de frecuencia en donde se encuentra información relevante (Amin et al., 2019).

Tomando esto en cuenta, otra rama de trabajos realiza la separación de la señal EEG en sus diferentes bandas de frecuencia para detectar los movimientos pensados. En este sentido, Dai y sus colaboradores han empleado la transformada wavelet por paquetes (WPT, por su acrónimo en inglés, Wavelet Packet Transform) para extraer las mejores características en el plano tiempo-frecuencia. De igual manera, se ha determinado que el mejor tamaño kernel varía de persona a persona y para eso, se han empleado diferentes tamaños de éste de manera simultánea para poder clasificar de mejor manera, a través de una CNN (Guanghai Dai, Jun Zhou, Jiahui Huang, 2020). Así bien, también se ha propuesto abordar el problema de la información en bandas únicas aumentando el número de bandas de frecuencia hasta llegar a 16, para poder posteriormente concatenar la información y clasificar mediante la información relevante por medio de una CNN. Se obtiene una eficiencia de la detección de un 80% (Zhang et al., 2019).

A partir de los trabajos presentados, es importante notar que se llega a la misma exactitud usando dos áreas distintas de análisis. Un área adicional consiste en el uso del método de CSP, aunado a un algoritmo que realiza una selección de manera automática de la banda de frecuencia con las mejores características, para así después aplicar filtros espaciales. Dicho método, aunado a una CNN optimizada por el método Bayesiano, muestra resultados de un 80.03% de exactitud (Olivas-Padilla & Chacon-Murguía, 2019). Así mismo, Rong (2020) nota que al remplazar una sola convolución de gran tamaño por varias pequeñas y continuas resulta en una mejor clasificación con un 82.8% de exactitud (Rong, 2020).

En el campo nacional, diversos investigadores han abordado el problema de diferentes maneras a lo largo de los años y se ha visto una medra significativa con el avance de estos. A inicios del 2012, investigadores de Puebla, México, realizaron investigaciones basándose en el método de análisis autorregresivo y en la extracción de características por el método de Fisher. Pese a obtener buena exactitud de clasificación (80.8 %) el método es lento y puede ser optimizado con técnicas más recientes como lo son las CNNs (D’Croz-Baron et al., 2012). Batres-Mendoza y colaboradores abordaron el problema haciendo uso del análisis de la señal

basado en cuaterniones para clasificar las señales en cuestión. Pese a que en su momento fue una mejora comparada con la investigación previa, es un método que se descarta por tener un resultado pobre (41.7% de exactitud) (Batres-Mendoza et al., 2016, 2017). Vega y colaboradores, empleando señales de EEG provenientes de MI de manos, pies y lengua, determinaron la efectividad de diversos métodos de extracción de características, como lo son: la correlación cuadrada de Pearson (R^2), el análisis de componente principal (PCA, por su acrónimo en inglés, Principal Component Analysis), el análisis de componente kernel principal (kPCA, por su acrónimo en inglés, kernel Principal Component Analysis) y el filtro rápido basado en correlaciones (FCBF, por su acrónimo en inglés, Fast Correlation Based Feature). Así mismo también evaluaron la efectividad de diversos clasificadores: el LDA, la máquina de soporte de vectores (SVM, por su acrónimo en inglés, State Vector Machine) y la RN como algoritmos de aprendizaje. Determinaron que el FCBF en conjunción con la SVM mostraban los mejores resultados con un 68.71% de exactitud. (Vega et al., 2016). Por otro lado, investigadores del Instituto Tecnológico de Chihuahua, obtuvieron un 81.58% de exactitud en la clasificación, con el método de CSP como método de extracción de características y la SVM como técnica de clasificación con MI de ambas manos y pies (Olivas-Padilla et al., 2017).

A nivel local, dos investigadores de la Universidad Autónoma de Querétaro, realizaron de manera paralela metodologías para la detección de MI en donde ambos abordaron la descomposición empírica de modos, pero difiriendo en el método de extracción de características; se usó teoría de fractales en una y entropías en otra, dando como resultado un 65% contra un 70.58% de eficiencia respectivamente, resultando evidente que el uso de las entropías puede ser mejor para la extracción de características de señales de EEG (Cruz Ramírez, 2018; Salazar Guerrero, 2018). Posteriormente y abordando señales de epilepsia de EEG, se realizó otra investigación en donde se abordó la detección anticipada de eventos epilépticos aquí se usó la WPT y tres diferentes fractales: Katz, Higuchi y Box. Una vez obtenidas las bandas de frecuencia de características, se usó una RN a modo de clasificador, obteniendo un 95% de eficiencia. (Pérez Sánchez, 2019). Por otro lado, también en la UAQ, investigadores recolectaron señales de EEG de 5 sujetos sanos, para realizar las tareas de MI correspondientes a pie y MD en periodos de 3.5 s con descansos entre ellos de aproximadamente 2 s. Se preprocesó cada toma usando algoritmo de separación de fuente a

ciegas (BSS) para después pasar por la transformada wavelet continua (CWT) con ventana de 1 s. Con los datos preprocesados, se introducen a la CNN para su clasificado. La CNN se desarrolló usando capas de convolución intercaladas con capas de pooling en el medio y como parte final una etapa de “aplanado “. Finalmente, se validó la información y se comparó con otros métodos, dando como resultado un 94.66% de exactitud. Este resultado es interesante de mencionar por la efectividad que se logra (Ortiz-Echeverri et al., 2019).

A partir de la información presentada en esta sección, se observa que las metodologías más efectivas hacen uso características estadísticas o bien de la búsqueda de patrones espaciales en las señales EEG, acopladas con un clasificador basado en técnicas de inteligencia artificial avanzada, como las redes neuronales. En este sentido, debe notarse que la búsqueda de cambios geométricos, así como su cuantificación puede generar características cuyos valores numéricos estén más separados, logrando disminuir la carga computacional del clasificador sin sacrificar la exactitud del clasificador, siendo un área que debe ser explorada.

1.3. Justificación

El ser humano tiende constantemente a desarrollar tecnología que mejore su calidad de vida, o bien, que facilite las tareas realizadas en cualquier ámbito. Por esto, diversos métodos son propuestos por investigadores de todo el mundo para abrir pauta a soluciones, así como a mejores estrategias de resolver problemáticas. Los sistemas BCI tienen como estructura general, en primer lugar, la adquisición de la información (comúnmente de señales de EEG) y como última etapa el control de algún sistema de actuadores (Chen et al., 2008). Con esto dicho, resulta particularmente interesante para la neurociencia el gran potencial que dichos sistemas tienen para mejorar el desarrollo cognitivo y funcional; así como el gran potencial que éstas tienen al ser empleadas para reemplazar o restaurar funciones de personas discapacitadas en materia de desórdenes neuromusculares, infartos, traumas cerebrales o lesiones a la médula espinal (Teo et al., 2018).

Ya que en México y en el mundo, las discapacidades de naturaleza motriz son las de mayor incidencia (INEGI, 2017), la principal justificación de este proyecto de tesis es desarrollar un método para poder clasificar y caracterizar señales de EEG de MI, de manera no invasiva, para su empleo en una BCI en trabajos futuros. Dicha problemática, tiene como

principal dificultad la exactitud de clasificación, así como la gran carga computacional del método de extracción de características (entorpeciendo el proceso). Dichos puntos, de ser abordados de manera correcta y elegidos los métodos adecuados, podrían marcar una diferencia.

1.4. Descripción del problema

En todo momento, el cerebro se encuentra enviando señales a todo el cuerpo. Hay diferentes técnicas que permiten visualizar e interpretar dichas señales en características que puedan ser entendibles y manipulables. Un ejemplo de estas señales son las EEG, mismas que tienen una naturaleza complicada en términos de la elección de las técnicas de procesamiento de señales, ya que son altamente no lineales, inmersas en un ruido considerable, además de ser no estacionarias. La metodología que use este tipo de señales debe tomar en cuenta las características antes mencionadas, ya que de esta manera la exactitud y confiabilidad del método resultante no se verán afectadas. En este sentido, diversos algoritmos basados en la cuantificación de los cambios geométricos de una señal no estacionaria han sido propuestos recientemente, dando resultados efectivos en el procesamiento de señales fisiológicas como el electrocardiograma y electromiograma (Burns et al., 2020; George et al., 2017; Murugappan et al., 2020), por lo que su uso puede resultar en la integración de una metodología robusta y confiable que requiera de un clasificador con menor complejidad, como el perceptrón multicapa, logrando mejorar los resultados presentados en el Estado del Arte. Estas consideraciones indican la necesidad de explorar los algoritmos antes mencionados y verificar su rendimiento en señales EEG, pues de esta manera podría ser posible generar sistemas BCI robustos y confiables.

1.5. Hipótesis y objetivos

1.5.1. Hipótesis

Mediante la utilización de algoritmos de extracción de patrones no lineales y herramientas de análisis en tiempo-frecuencia, es posible detectar si una persona mueve imaginariamente las manos o los pies usando la señales de electroencefalografía. Haciendo una comparativa de métodos, se pueden seleccionar los mejores para tener un mejor

rendimiento comparado con trabajos similares al estado del arte que buscan resolver el mismo problema.

1.5.2. Objetivo general

Desarrollar una metodología para identificar si una persona mueve imaginariamente las manos o los pies usando señales EEG y empleando herramientas de descomposición de señales en el dominio tiempo-frecuencia, algoritmos de extracción de patrones no lineales y un clasificador inteligente.

1.5.3. Objetivos particulares

- 1) Desarrollar un algoritmo de lectura de las señales EEG, empleando el software MATLAB, a fin de poder cargarlas y ser procesadas.
- 2) Programar el algoritmo de tiempo-frecuencia necesario (como lo es la transformada wavelet por paquetes) para descomponer la señal EEG en sus diferentes bandas de frecuencia, a fin de encontrar aquella que tenga la información relevante para poder ser usada en la detección de patrones asociados al movimiento imaginario de manos y pies.
- 3) Programar los algoritmos de reconocimiento de patrones no lineales, para poder cuantificar los cambios que se tienen en cada una de las bandas de frecuencia de las señales EEG.
- 4) Realizar un análisis exhaustivo, empleando las propiedades estadísticas de las características encontradas, a fin de determinar cuál banda de frecuencia es la que contiene los mayores cambios.
- 5) Programar un clasificador basado en algoritmos inteligentes, como lo es una red neuronal multicapa, para poder generar un sistema que permitan si una persona movió imaginariamente el pie o la mano.
- 6) Evaluar la eficacia de cada uno de los clasificadores desarrollados, empleando la matriz de confusión, para determinar cuál es el más exacto.

1.6. Planteamiento general del problema

El presente trabajo de tesis planteará una solución que requiere de cuatro pasos principales, mencionados de manera gráfica en la Figura 1.1

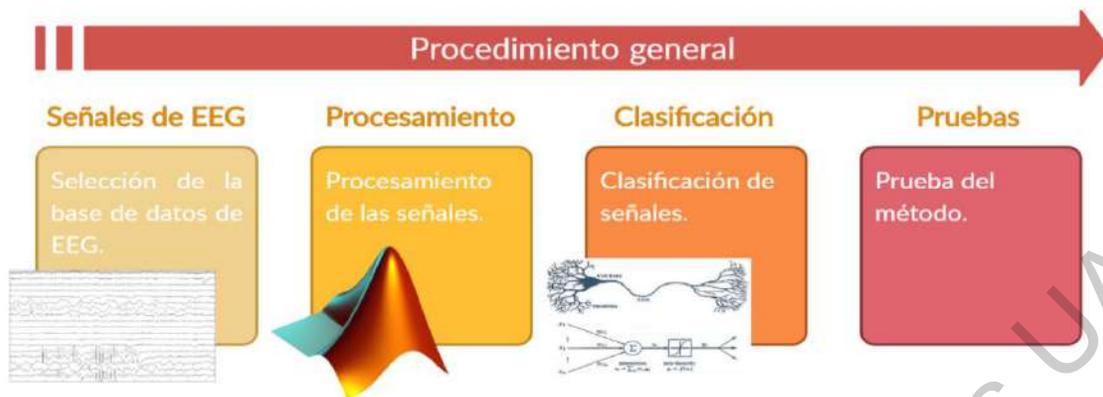


Figura 1.1. Planteamiento general del problema.

En el primer paso, se descargará y preparará la base de datos correspondiente con todos los criterios necesarios, como lo es, permiso de la institución que realizó la base de datos, anonimidad de los pacientes, entre otros. El segundo paso constará de la extracción de características de las señales divididas en sus diferentes bandas de frecuencias, a fin de obtener características únicas que serán usadas en el tercer paso, el clasificador, ya que de esta manera será posible saber si la persona movió imaginariamente ya sea la mano o el pie, para finalmente en el cuarto paso, poder validar la metodología resultante con las señales remanentes de la base de datos.

CAPÍTULO 2

Fundamentación Teórica

2.1. Señales EEG

La electroencefalografía es una de las técnicas más antiguas y mejor establecidas para leer la actividad eléctrica del cerebro, teniendo diversas aplicaciones en las prácticas neurológicas (Castro Guzman et al., 2019). Ésta fue introducida en humanos por el doctor psiquiátrico Alemán Hans Berger en 1924 (Louis et al., 2016). La electroencefalografía se caracteriza por tener una alta resolución temporal (apta para seguir los rápidos y dinámicos cambios), y, por lo tanto, señales resultantes con ritmos bien definidos, con frecuencias específicas (usualmente entre 1Hz y 100 Hz) y potenciales evocados para eventos específicos (de amplitudes entre 10–100 μ V aproximadamente) (Bansal & Mahajan, 2019; Michael-Titus et al., 2010; Srinivasan & Nunez, 2012). La Tabla 2.1 muestra un resumen de las principales componentes de las señales EEG. (Bansal & Mahajan, 2019; Keenan et al., 2013).

Onda	Forma de onda	Ancho de banda (Hz)	Principales características
Delta		0.5-4 Hz	Presentes en el sueño o meditación profunda, en este estado, no hay sentido del entorno, se promueve la regeneración por parte del cuerpo.
Teta		4-8 Hz	Presentes en sueño y meditación ligera, estas ondas, reflejan aprendizaje y memoria, están presentes al despertar y en imaginación vívida
Alfa		8-12 Hz	Presentes en pensamientos tranquilos, en algunos estados de meditación, en ER cerebral y en calma/alerta mental.
Beta		12-30 Hz	Presentes en estados de completa atención y conciencia del mundo exterior, asociadas a tareas cognitivas y resolución de problemas.
Gama		>30 Hz	Estas ondas se relacionan con procesos simultáneos de información de diferentes áreas en el cerebro, reflejan el tránsito de información rápida, son las más sutiles.

Tabla 2.1. Tipos de ondas cerebrales y sus principales características.

2.1.1. Adquisición de señales EEG

Las señales de EEG, son principalmente el producto de la suma e inhibición de los potenciales excitatorios postsinápticos, en su mayoría provenientes de células piramidales de las capas más externas de la corteza cerebral. Para que un impulso eléctrico se sume y pueda atravesar el cuero cabelludo, una gran cantidad de neuronas deben simultáneamente excitarse con un impulso similar (Keenan et al., 2013).

Esta diferencia de potencial se adquiere mediante un par de electrodos (uno de referencia y otro estándar), posicionados en diferentes regiones del cuero cabelludo (Castro Guzman et al., 2019). En la Figura 2.1 se puede observar un esquema de un electrodo de diámetro, cuyo tamaño es menor a 1 cm, colocado en la superficie del cuero cabelludo, que en conjunto con el cráneo crean una capa cuya longitud es de entre 1 y 1.2 cm. a través de la cual viajará la señal de EEG. Se puede remarcar que para un EEG las señales captadas serán de los sitios cercanos a [a, b, d, e, g y h] siendo estos los más proximales a la superficie, mientras que las zonas [c y f] serán imperceptibles (Srinivasan & Nunez, 2012).

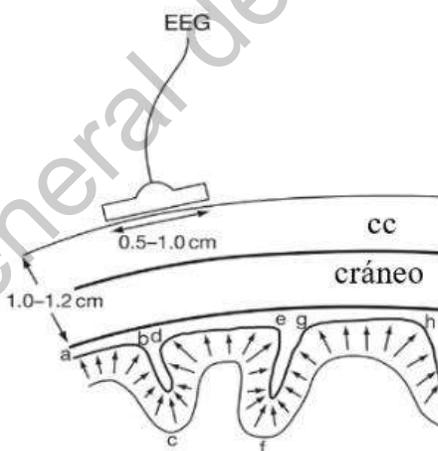


Figura 2.1. Esquema: electrodo, (cc)cuero cabelludo, cráneo y corteza cerebral.

Por convención, se emplea el “sistema de electrodos estandarizado 10-20” en donde se divide el cráneo en planos transversos de 10% y 20% del área. En este sistema, los electrodos están marcados con números y letras específicas para cada región. En la Figura 2.2, se observa el sistema 10-20 con sus diferentes anotaciones según el lóbulo y hemisferio: O para occipital, T para temporal, P para parietal, F para frontal, A para región auricular, los numeros pares para hemisferio derecho, numeros impares para hemisferio izquierdo y Nasion

e Inion para electrodos de referencia como se puede ver en la Figura 2.3. Así, se puede tener una medida para la diferencia de potencial en una región en específico a lo largo del tiempo (Bansal & Mahajan, 2019).

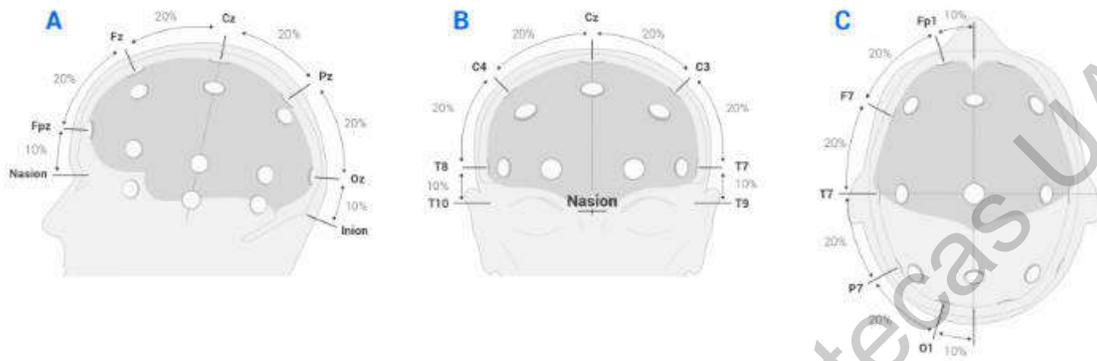


Figura 2.2. Sistema de electrodos 10-20. A, vista lateral; B, vista posterior; C, vista superior.

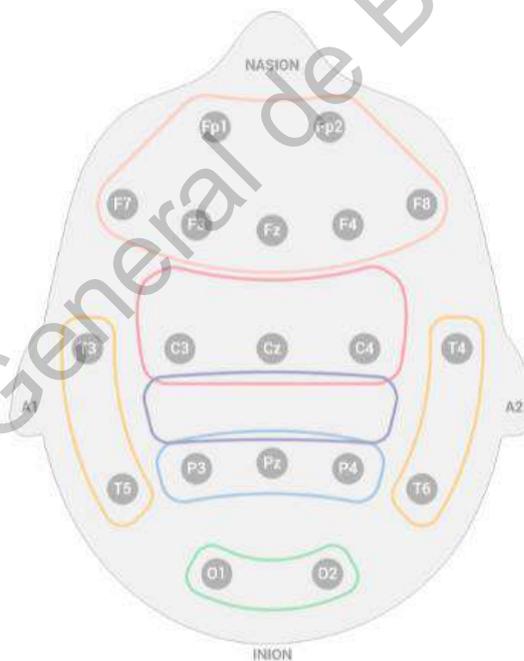


Figura 2.3. Sistema de electrodos 10-20. Acomodo de 19 electrodos. • área del NAS *je, • área auditiva, • área sensoriomotora, • área somatosensorial, • área estímulo sensorial, • área visual.

Las señales recogidas por los electrodos son provenientes del cerebro, del ruido ambiental producido por sistemas electricos y por artefactos biológicos. Estos artefactos pueden ser causados por movimiento corporal, de corazón, muscular, ocular o de lengua. Los artefactos suelen mezclarse con la señal que se busca y puede ser un problema en ciertos

casos. Comúnmente se puede deshacer de ellos usando un filtro pasa bandas (Bansal & Mahajan, 2019; Keenan et al., 2013; Srinivasan & Nunez, 2012). En general, las respuestas cerebrales adquiridas, son preamplificadas para mejorar la señal y filtradas para remover todo el ruido y artefactos existentes. Posteriormente, se procede a convertir la señal a formato digital haciendo uso de un convertidor analógico-digital (ADC). Una vez adquiridas, las señales cerebrales son amplificadas, digitalizadas y transmitidas a una interface de computadora para su posterior procesamiento (Bansal & Mahajan, 2019).

2.1.2. Movimiento Motor Imaginario

El término movimiento motor imaginario se refiere a la simulación mental de movimientos del cuerpo. Este acto representa un rol crucial en el aprendizaje y control de las extremidades del cuerpo humano (Scherer & Vidaurre, 2018). Esta acción puede ser llevada a cabo en dos diferentes modalidades; depende en cómo se vea la persona, a sí misma haciendo la acción en primera o en tercera persona. De cualquier manera, ambos casos son válidos y pueden ser empleados como MI (Mehler et al., 2019).

En la corteza cerebral, existen diferentes áreas asociadas a: sentidos, capacidad cognitiva, pensamiento, entre otras. Dos de ellas y en las que se manifiesta el MI es la corteza motora primaria (c) y la corteza sensorial primaria (d), como se puede ver en la Figura 2.4, están ubicadas lateral y medial en los hemisferios cerebrales, justo enfrente del surco central y por detrás de este respectivamente (Georgopoulos, 1997). Dicho esto, en caso de querer captar señales de dichas cortezas para poder recabar información de MI de un individuo, es necesario hacer uso de los electrodos situados en C4 y C3 (Scherer & Vidaurre, 2018).

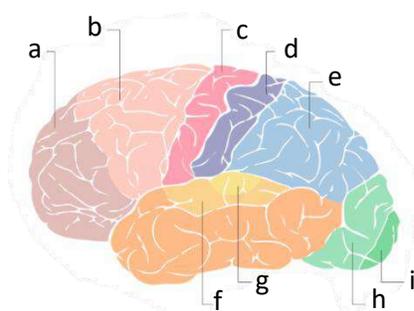


Figura 2.4. Lóbulo izquierdo cerebral y áreas asociadas. a, corteza prefrontal; b, área somática motora; c, corteza motora primaria; d, corteza primaria sensorial; e, área somatosensorial; f, área de asociación auditiva; g, corteza auditiva; h, área de asociación visual; i, corteza auditiva.

2.2. Herramientas de descomposición de señales en tiempo-frecuencia

Como se mencionó en el capítulo previo, existen diversas metodologías que obtienen información relevante para clasificar los diferentes tipos de movimientos detectados en las señales EEG. Comúnmente, se pueden clasificar en tres tipos:

- Técnicas en el dominio del tiempo: estos métodos usan como característica principal las variaciones en el tiempo de una señal. Algunas de estas técnicas empleadas para señales de EEG son valor medio, integral cuadrada simple, amplitud de Wilson, entre otras (Khorshidtalab et al., 2012).
- Técnicas en el dominio de la frecuencia: los métodos en materia de la frecuencia, se valen de herramientas como la potencia espectral, la transformada de Fourier corta y la transformada rápida de Fourier empleada en EEG, por ejemplo, para identificar tareas cerebrales con respecto a los picos del espectro resultante (Medina et al., 2018).
- Técnicas en el dominio de tiempo-frecuencia: un análisis de tiempo-frecuencia es esencial para el procesado de señales; generalmente y dependiendo de la técnica, se requiere extraer ciertos eventos o características en frecuencias exactas o bien en tiempos específicos presentes en las señales (Chui & Mhaskar, 2016; Ewins, 2001).

Evidentemente, a partir del uso de las herramientas de descomposición tiempo-frecuencia es posible que los cambios que generan los diferentes tipos de movimientos en las señales EEG puedan visibilizarse de mejor manera, lo que por ende podría generar metodologías más efectivas para la clasificación de las mismas. Una de las herramientas tiempo frecuencia es la Transformada Wavelet (WT, por su acrónimo en inglés, Wavelet Transform) (Mitrović et al., 2010). Las características de esta técnica se explorarán en las siguientes subsecciones.

2.2.1. Transformada Wavelet

El particular interés principal de la WT es el realizar el análisis de señales no estacionarias; esta provee una alternativa a la clásica transformada de Fourier de tiempo

reducido (STFT). Mientras la STFT emplea una sola ventana de análisis, la WT usa diversas ventanas: ventanas cortas para frecuencias altas y ventanas largas para bajas frecuencias (Rioul & Vetterli, 1991). Como se puede observar en la Figura 2.5, la WT tiene un mejor desempeño por su característica dinámica de ventanas de diferentes tamaños en todo el tiempo, para diferentes frecuencias (Kehtarnavaz, 2008).

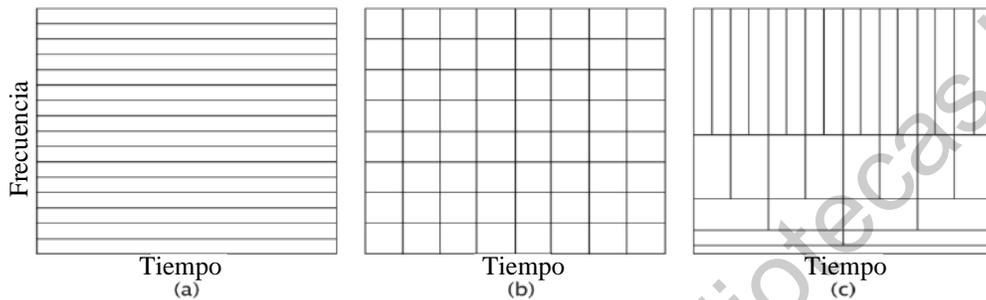


Figura 2.5. Comparación de herramientas de descomposición en tiempo-frecuencia. (a) Transformada discreta de Fourier, (b) STFT, (c) WT.

A diferencia de la transformada de Fourier, en donde se utilizan funciones trigonométricas (seno y coseno) como funciones base, en la WT se hace uso de funciones ortogonales, mejor conocidas como ondoletas (wavelet) madre. Esto abre pauta para que sea posible investigar diferentes wavelets madre en diferentes señales. Algunas de las ondoletas madre que se emplean son la Daubechies, Coiflets, Haar y Sombrero Mexicano, por mencionar las más importantes. Dentro de la familia de las ondoletas madre Daubechies, existe la db44. Esta ondoleta madre en particular, posee características simétricas, así como picos afilados que pueden ser bien acoplados con las señales naturales. Algunas de las señales con las que ha demostrado tener amplia similitud es con las señales de EEG (Rafiee et al., 2011).

Existen diferentes tipos de WT entre ellas están: CWT, WT Discreta (DWT, por su acrónimo en inglés, Discrete Wavelet Transform) DWT rápida, WPT por mencionar las más usadas (Donald et al., 2009). La CWT está definida por la ecuación:

$$\gamma_{\kappa, \chi} \int_{-\infty}^{\infty} f(t) \psi_{\kappa, \chi}^*(t) dt \quad 2.1$$

donde $f(t)$ es una función continua integrable en el tiempo. El operador $*$ se encuentra ahí para conjugaciones complejas. La ondoleta madre $\psi(t)$ es continua en tiempo y frecuencia, y se modificada en diferentes ondoletas hijas por los coeficientes κ de escalamiento y χ de desplazamiento:

$$\psi_{\kappa,\chi} = \frac{1}{\sqrt{\kappa}} \psi\left(\frac{t - \chi}{\kappa}\right) \quad 2.2$$

En la Figura 2.6, podemos apreciar la ondoleta madre de tipo Sombrero Mexicano con diferentes escalas y diferentes posiciones, en donde $\kappa \in \mathbb{R}^+$ y $\chi \in \mathbb{R}$. La ondoleta mostrada al centro, es la ondoleta madre base, es decir, que no está escalada ni trasladada, mientras que las gráficas ubicadas a los lados son las ondoletas hijas (Nikookar, 2013). Evidentemente, al modificar tanto la escala como el desplazamiento de la ondoleta madre es posible obtener las componentes de las diferentes escalas de frecuencias que la señal tiene. La CWT permite modificar los parámetros antes mencionados sin ninguna restricción, a costa de requerir una carga computacional elevada para poder calcular los resultados. Por esta razón, deben explorarse alternativas que permitan obtener los mismos resultados que la CWT pero con un costo computacional menor (Lotfollahi-Yaghin & Koohdaragh, 2011; Shao & Sun, 2001).

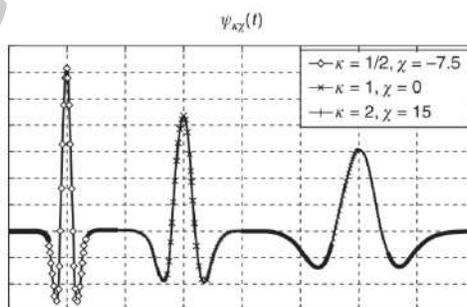


Figura 2.6. Ondoleta madre en diferentes escalas y posiciones.

2.2.1.1. Transformada Wavelet por Paquetes

Un Banco de Filtrado es por definición, un conjunto de filtros vinculados por submuestreo y sobremuestreo en donde se usan filtros pasa altas y pasa bajas (Hong et al.,

2005). Esta herramienta, es empleada para la DWT y también para la WPT de tal manera que se puede hacer una descomposición usando bancos de filtrado de dos canales a lo largo de un algoritmo jerárquico conocido como algoritmo piramidal (Nikookar, 2013).

Normalmente, la DWT implementa un banco de filtrado no uniforme, pues solamente la señal resultante del filtro pasa bajas es descompuesta iterativamente. En la WPT, se usa la estructura de descomposición tipo árbol o piramidal (Figura 2.7) para implementar el algoritmo de descomposición en las ramas del filtro pasa altas (detalles, D) y el filtro pasa bajas (aproximaciones, A) (Jaffery & Islamia, 2014). De esta manera, ya que las altas frecuencias están descompuestas de la misma manera que las bajas frecuencias, la WPT tiene una resolución en frecuencias igualmente espaciada (Nikookar, 2013).

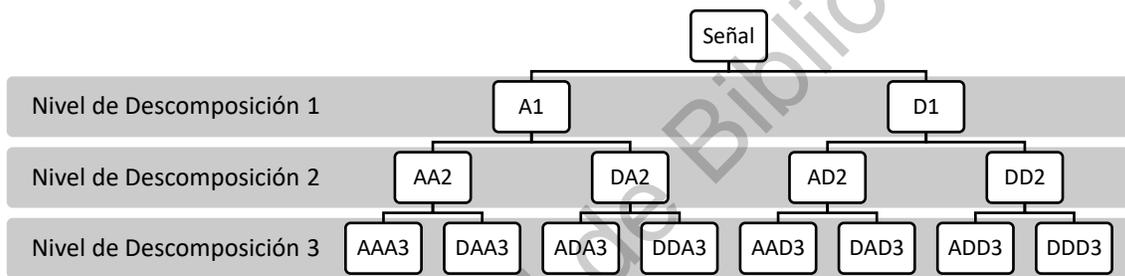


Figura 2.7. Diagrama de árbol de detalles y aproximaciones de WT por Paquetes.

La WPT está definida por:

$$W_{j,k}^n(t) = 2^{j/2} \xi^n(2^j t - k) \quad 2.3$$

donde j representa el coeficiente de escalamiento, k el coeficiente de traslación, n el coeficiente de modulación y ξ los coeficientes de la WT a cierto nivel, que son calculados por la convolución de la wavelet y el filtrado a escala de los coeficientes de la wavelet por paquetes del anterior nivel. Así bien, la WPT, se obtiene a través de las ecuaciones recursivas:

$$W^{2n}(t) = \sqrt{2} \sum_{k=-\infty}^{\infty} h(k) \xi^n(2t - k) \quad 2.4$$

$$W^{2n+1}(t) = \sqrt{2} \sum_{k=-\infty}^{\infty} g(k)\xi^n(2t - k) \quad 2.5$$

en donde $g(k)$ y $h(k)$ denotan los coeficientes de las funciones wavelet. Ahora, únicamente es necesario realizar un banco de filtrado de dos canales para cada una de las aproximaciones y detalles (Nikookar, 2013). Es importante notar que tanto j como k se calculan usando potencias de 2, lo que optimiza el consumo de recursos que los algoritmos emplean para estimar la respuesta (Nikookar, 2013).

2.3. Características no lineales

La actividad eléctrica del cerebro, medida por un EEG, muestra un ambiente complejo con propiedades dinámicas no lineales; por esto, los métodos no lineales son los predilectos para abordar este tipo de señales, en lugar de los tradicionales métodos lineales (Natarajan et al., 2004). Dicho de otra manera, no se pueden representar adecuadamente señales de EEG por modelos lineales. Esto se ha comprobado múltiples veces, comparando métodos lineales y no lineales, siendo estos últimos los que destacan por sus buenos resultados (Hazarika, 1997). Entre los métodos que se sobresalen para abordar estas características no lineales y poder interpretarlas está la FD y las Entropías (Amarantidis & Abásolo, 2019; Bialy, 1989).

2.3.1. Fractales

Los fractales son sistemas espaciales o temporales, jerárquicos y en algunos casos complejos que se rigen por algoritmos iterativos y reglas a escala. Los patrones con este tipo de sistemas, se repiten por definidos rangos y escalas como se puede apreciar en la Figura 2.8 (Snyder & Vázquez, 2005; Tuller & Or, 2004). La geometría fractal puede ser aplicada para describir cuantitativamente la irregularidad y forma de diferentes objetos o señales, estimando su FD (Dauphiné, 2017).

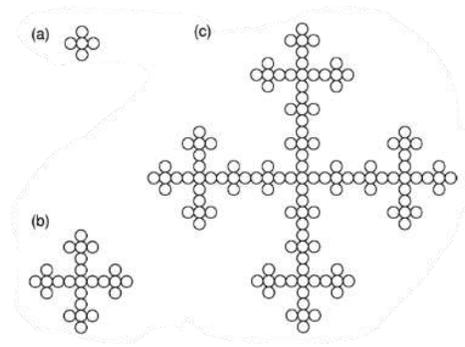


Figura 2.8. Fractal en diferentes niveles jerárquicos. (a) Nivel 1, (b) Nivel 2, (c) Nivel 3.

La FD, es usada para estimar la similitud o afinidad con la misma señal, esto puede ser determinado con señales (principalmente resultante de descomposición wavelet) o bien analizando imágenes por medio de las irregularidades promedio que presente la señal (Dauphiné, 2017; Mwema et al., 2020). Existen diferentes tipos de dimensiones fractales y estas pueden ser calculadas de diferentes maneras, por ejemplo, por correlación, espectros de energía, descomposiciones de Fourier, descomposiciones wavelet, entre otras técnicas (Dauphiné, 2017).

2.3.1.1. Box Counting

La FD Box Counting (BFD) tiene cierta resistencia al ruido por lo cual puede extraer características de diferentes complejidades de una señal previamente procesada (Li et al., 2018). Ésta es calculada suponiendo que una malla de cajas en una cuadrícula, envuelve la señal en el tiempo. Así, estima la fractalidad sobre las cajas ocupadas.

Por definición, la aproximación de la BFD es:

$$BFD \cong - \frac{\ln \left(\sum_{i=1}^{N-1} \frac{|x_{i+1} - x_i|}{\Delta t} \right)}{\ln(\Delta t)} \quad 2.6$$

donde, x_i es una función en el tiempo, con N número de muestras, en un intervalo de tiempo Δt (Piña-Vega et al., 2021).

2.3.1.2. Katz

Para una señal en el tiempo (x_i, y_i) con N número de muestras, la FD de Katz (KFD), se define como:

$$KFD = \frac{\log(N)}{\log(N) + \log\left(\frac{d}{L}\right)} \quad 2.7$$

donde d está definida como la mayor distancia entre la primera muestra y las subsecuentes, así como L que es la distancia Euclidiana entre puntos sucesivos de la misma señal (Katz, 1988; Piña-Vega et al., 2021); dichas señales se definen por:

$$L = \sum_{i=2}^N \sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2} \quad 2.8$$

$$d = \max((x_i - x_{i-1})^2 + (y_i - y_{i-1})^2) \quad 2.9$$

2.3.1.3. Higuchi

Para poder implementar la FD de Higuchi (HFD), se debe construir una nueva serie de tiempo (X_k^m) proveniente de nuestra señal, de número de muestras N , de origen; está, definida de la siguiente manera:

$$X_k^m = X(m), X(m+k), X(m+2k), \dots, X\left(m + \left[\frac{N-m}{k}\right] \cdot k\right) \quad 2.10$$

donde m es la muestra inicial de tiempo y k el intervalo entre dos muestras sucesivas. Para cada secuencia X_k^m el promedio de longitud L es calculado con la siguiente ecuación:

$$L_m(k) = \frac{\left\{ \left(\sum_{i=1}^{\left[\frac{N-m}{k}\right]} |X(m+ik) - X(m+(i-1) \cdot k)| \right) \left(\frac{N-1}{\left[\frac{N-m}{k}\right] \cdot k} \right) \right\}}{k} \quad 2.11$$

Posteriormente, se calcula la longitud promedio total, definida a continuación:

$$L(k) = \sum_{m=1}^k L_m(k) \quad 2.12$$

Para finalmente, transformarse en:

$$\ln[L(k)] \propto D \ln\left(\frac{1}{k}\right) \quad 2.13$$

donde la pendiente D es considerada el valor de la HFD de una señal en particular (Higuchi, 1988; Piña-Vega et al., 2021).

2.3.1.4. Sevcik

El método FD de Sevcik (SFD) es considerado una variación de la KFD, pero en este caso, la señal de tiempo es normalizada como se muestra a continuación:

$$x_i^* = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad 2.14$$

$$y_i^* = \frac{y_i - \min(y)}{\max(y) - \min(y)} \quad 2.15$$

Así bien, la SFD de la señal previamente normalizada es estimada por la siguiente ecuación:

$$SFD = \frac{\log(L) + \log(2)}{\log(2 * (N + 1))} \quad 2.16$$

donde L es la distancia Euclidiana entre los puntos sucesivos previamente normalizados:

$$L = \sum_{i=2}^N \sqrt{(x_i^* - x_{i-1}^*)^2 + (y_i^* - y_{i-1}^*)^2} \quad 2.17$$

2.3.2. Entropías

La entropía es conocida como una medida no lineal, capaz de describir la aleatoriedad en una señal en el tiempo. Por esta razón, ha sido aplicada en diferentes campos para detectar y cuantificar cambios en las formas de onda, así como en vibraciones, señales de EEG y ECG. A lo largo de los años, se han presentado diversos algoritmos de entropía, para calcular la aleatoriedad de una señal en el tiempo, entre estos métodos, se encuentran Shannon, Aproximación, Permutación, entre otras (Amezquita-Sanchez, 2021).

2.3.2.1. Shannon

Shannon presenta el concepto de “información” de una fuente discreta sin memoria (en donde los valores de salida son independientes de cada momento de tiempo) como una función que cuantifica la “incertidumbre” de una variable aleatoria (los posibles valores que puede tomar a la salida) en cada punto discreto del tiempo (Espinosa-Paredes, 2021). En pocas palabras, entre mayor complejidad geométrica tenga la señal, “mayor incertidumbre” tendrá, pues no habrá valores que se repitan. La entropía de Shannon (ES), mide la aleatoriedad de la señal como se muestra en la ecuación:

$$ES(X) = - \sum_{i=1}^k p(x_i) \log_2[p(x_i)] \quad 2.18$$

donde x_i denota las posibles salidas que pueden ser tomadas por la señal X con la probabilidad $p(x_i)$ (Piña-Vega et al., 2021; Shannon, 1948).

2.3.2.2. Permutación

Así como otras entropías, la entropía de Permutación (EP) mide la incertidumbre en la distribución de la frecuencia. La EP tiene dos parámetros predefinidos, el “orden” que es el número de puntos de datos en cada subanálisis; y el “retraso”, que es el número de muestras abarcadas para cada sub análisis (Olofsen et al., 2008). Para calcular el valor de la entropía de permutación de una señal en el tiempo con N muestras es primero dividida en una serie de nuevas señales X_i en orden ascendente de acuerdo a el retraso y una dimensión embebida m (Amezquita-Sanchez, 2021).

$$X_i = [x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}] \quad 2.19$$

Así bien, la EP está definida por:

$$EP(m) = - \sum_{\pi=1}^{m!} p(\pi) \ln(\pi) \quad 2.20$$

En donde para cada valor de m existen $m!$ valores posibles de permutación o patrones π con frecuencias relativas:

$$p(\pi) = \frac{f(\pi)}{[N - (m - 1)\tau]} \quad 2.21$$

donde $f(\pi)$ representa la frecuencia de ocurrencia de π en la serie de tiempo. Así bien el valor de la entropía de permutación calculada está normalizado de acuerdo a:

$$EP = \frac{-\sum_{m=1}^{m!} p(\pi) \ln(\pi)}{\ln(m!)} \quad 2.22$$

2.3.2.3. Aproximación

La entropía de aproximación (EA) está definida por:

$$EA = \Phi^m(r) - \Phi^{m+1}(r) \quad 2.23$$

En donde:

$$\Phi^m(r) = \left(\frac{1}{N - m + 1} \right) \sum_{i=1}^{N-m+1} \ln C_i^m(r) \quad 2.24$$

De los cuales $C_i^m(r)$ es un factor de normalización y r la tolerancia de la señal de tiempo.

$$C_i^m(r) = \left(\frac{d[X(i), X(j) \leq r]}{N - m + 1} \right) \quad 2.25$$

La distancia entre X_i y X_j , $d[X_i, X_j]$, está dada por:

$$d[X_i, X_j] = \max_{k=1,2,\dots,m} (|x(i+k-1) - x(j+k-1)|) \quad 2.26$$

2.4. ANOVA

La idea general del ANOVA, es tabular la variabilidad de todos los resultados del experimento, y dividirla en variabilidad entre grupo contra variabilidad dentro grupos. De esta manera, si la variabilidad entre grupos es mayor que la variabilidad dentro grupos, al menos uno de los grupos tiene una media que significativamente diferente. Esta, es una herramienta paramétrica que supone diferentes asunciones acerca de la distribución de los datos (Smalheiser, 2017):

- Cada grupo está muestreado desde una distribución normal.
- Cada punto del mismo grupo es independiente de otros, muestreados aleatoriamente y siguiendo la distribución.
- La varianza del grupo es similar.

2.4.1. ANOVA no Paramétrico

La prueba de Kruskal-Wallis, es una prueba no paramétrica también llamada “ANOVA de una vía en rangos” o “ANOVA no paramétrico”, que puede ser usada para determinar si hay diferencias estadísticas significantes entre dos o más grupos de una variable independiente en una variable dependiente ordinal o continua. Esta prueba no te dice cuál de los grupos comparados se desvía, pero sí te dice que dos grupos son diferentes, para su cálculo, es necesario tener más de 5 muestras por grupo y está definida por la siguiente ecuación:

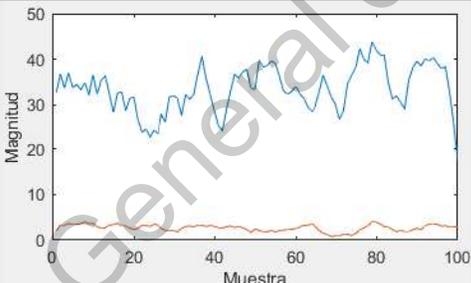
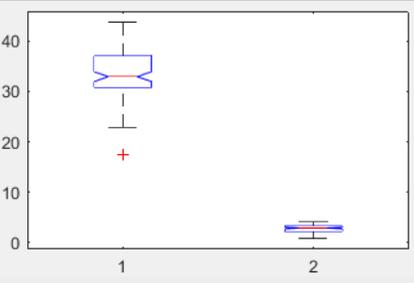
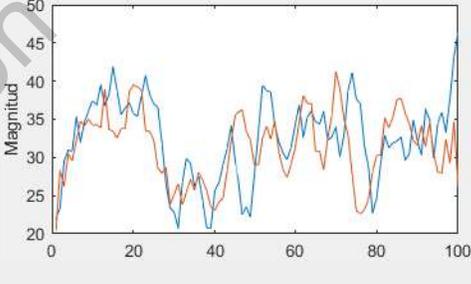
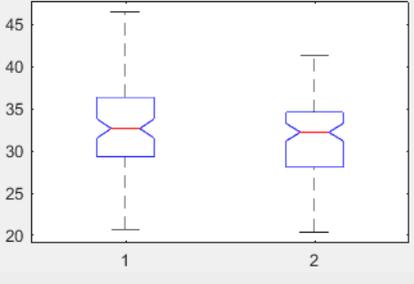
$$KW = \frac{12}{n(n+1)} \left(\frac{T_1^2}{n_1} + \frac{T_2^2}{n_2} + \dots + \frac{T_k^2}{n_k} \right) - 3(n+1) \quad 2.27$$

donde n_m es el tamaño de las muestras, n es el número total de muestras y T_m son las sumatorias de las muestras. Para conocer el valor-P asociado a ese resultado, se pueden consultar tablas de distribución probabilística (Lagrone, 2011).

2.4.2. Valor-P

El valor P, uno de los resultados de un ANOVA, indica la probabilidad para cierto modelo estadístico que cuando la hipótesis nula es verdadera, la sumatoria estadística debería ser igual o mayor que los resultados observados. Así bien, el valor P indica qué tan incompatible son los datos con respecto a un modelo estadístico específico. Mientras más pequeño sea el valor P, mayor incompatibilidad habrá entre los datos (Nahm, 2017).

Como ejemplo, se muestra en la Tabla 2.2 una comparativa de tres tipos de conjuntos de datos. El primero, son dos conjuntos de datos que difieren completamente entre sus elementos, se puede ver tanto en la disposición de las gráficas como en el diagrama de cajas y bigotes; de igual manera, esto se ve reflejado de manera numérica por el valor P de 0.0. En el segundo, con una muestra más afín, el valor P se aproxima más a uno con un valor de 0.1117. Por último, y como tercer ejemplo, se presentan dos conjuntos de datos con elementos similares estadísticamente; es tanta la similitud, que el valor P es de 0.8815, aproximándose en demasía a 1.

Valor P	Gráficas de conjuntos de datos	Diagrama de cajas y bigotes
0.0000		
0.1117		

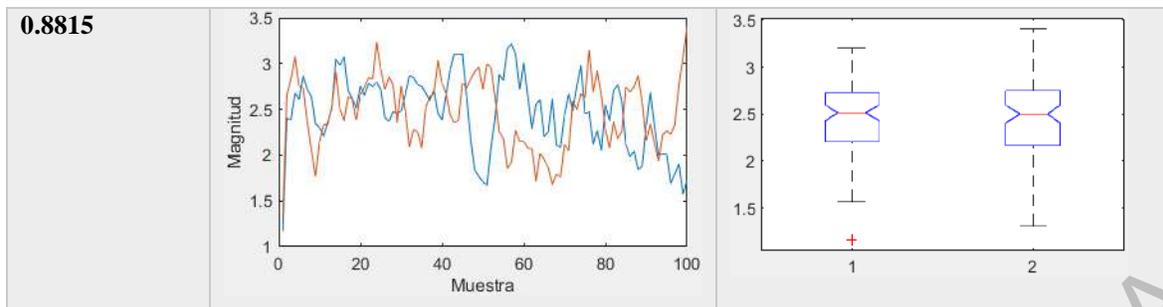


Tabla 2.2. Ejemplo de tendencia de Valor-P a 1 y 0 en diferentes conjuntos de datos.

2.5. Redes Neuronales

Las redes neuronales son herramientas estadísticas de modelado de información no lineal, compuestas de nodos altamente interconectados que pueden describir relaciones complejas entre entradas y salidas (Penm et al., 2013). Esta herramienta es una técnica de inteligencia artificial que imita la manera de trabajar del cerebro humano. Comúnmente, es empleada para resolver problemas complejos y extensos de diversas naturalezas.

Una RN está compuesta de capas donde cada una de estas se conforma por una serie de nodos, conexiones, pesos, bías, funciones suma y funciones de transferencia (Casas, 2020); donde se calcula una función a partir de las entradas del sistema por medio de la propagación de los valores obtenidos de las neuronas de entrada y las neuronas de salida y usando pesos como parámetros intermedios. La principal ventaja de estas herramientas de inteligencia artificial, es la habilidad de generalizar su aprendizaje adquirido en el entrenamiento y usarlo en nuevos casos (Neapolitan & Neapolitan, 2018).

2.5.1. Arquitectura y topología

La neurona es la unidad fundamental de una RN y se compone de diversas etapas como se puede ver en la Figura 2.9. Una neurona tiene a la entrada (input) una serie de atributos representados como nodos (p) los cuales serán analizados para poder tener una salida. Éstos constituyen la capa de entrada, también llamado vector de entrada. Estas entradas son modificadas por los pesos (W , que modifican la entrada según los parámetros establecidos), que pueden ser modificados de acuerdo a la bias (b) establecida (que es una corrección escalar), para producir una entrada a la red. Posteriormente el resultado (n) es pasado por una función de transferencia (f) para dar una salida (a) que puede ser la entrada

de otra neurona en una capa oculta intermedia o bien la salida final (Casas, 2020; Neapolitan & Neapolitan, 2018).

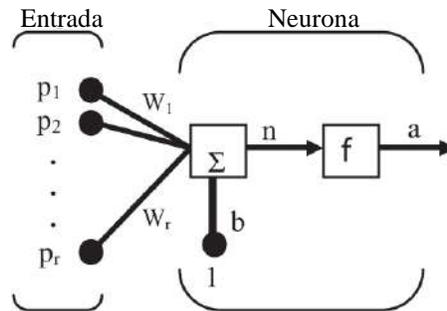


Figura 2.9. Estructura de una neurona. P : nodos de entrada, W : pesos, b : bias, n : salida del sumador, entrada de la función de transferencia, f : función de transferencia, a : salida.

Cuando múltiples neuronas se combinan para trabajar en paralelo, se forma una estructura llamada “capa”. Una RN está compuesta por diversas capas de neuronas en donde la salida de una capa constituye la entrada de la siguiente capa. Así bien, el número de entradas, capas intermedias, salidas, y el tipo de función de transferencia empleada, definen la arquitectura de una red. De esta manera, la arquitectura determina la topología de la red. Hay tres diferentes tipos de arquitectura de red que se pueden identificar:

- Red de capa única: consiste en un vector de entrada conectado a una sola capa de N número de neuronas.
- Red multicapa: se caracteriza por tener una o más capas intermedias a las cuales se les llama “capas ocultas”, como se muestra en la Figura 2.10 (Neapolitan & Neapolitan, 2018).
- Red recursiva: es una red con retroalimentación, en donde algunas de las salidas están conectadas a las entradas (Casas, 2020).

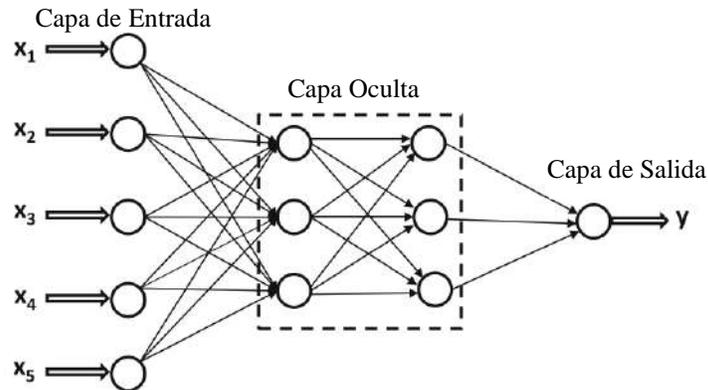


Figura 2.10. Esquema de una RN multicapa. En donde x : entradas, input layer: capa de entrada, Hidden layer: capa oculta, output layer: capa de salida e y : salida.

De manera general, para desarrollar el clasificador se usa la red multicapa, ya que ésta tiene la flexibilidad para detectar los patrones de clasificación y asociarlos a la clase que le corresponda. Para realizar este proceso, es necesario entrenar la red para que pueda detectar los patrones (Casas, 2020).

2.5.2. Algoritmo de entrenamiento

El proceso de aprendizaje es clave para las redes neuronales de la misma manera que para los humanos. En este proceso, se modifican los pesos y las bias de la red hasta que una cierta condición se ha alcanzado. El aprendizaje puede ser de una de tres maneras: aprendizaje supervisado, aprendizaje por refuerzo y aprendizaje no supervisado (Casas, 2020).

2.5.2.1. Aprendizaje supervisado

Las redes neuronales supervisadas, se caracterizan por tener a la entrada datos previamente analizados para obtener una salida deseada. La información de entrada es llamada “información de entrenamiento” y sus correspondientes salidas son llamadas el “objetivo”. En este caso, la RN trata de encajar el modelo a partir de cambios constantes en los pesos y las bias de la red para aproximar la salida de esta a los objetivos deseados. Esto es repetido iterativamente hasta que una medida estadística determina que ha sido exitosamente entrenada. Finalmente, se debe de probar la RN con una base de datos diferente a la del entrenamiento para probar la misma (Casas, 2020).

En este sentido, el algoritmo de entrenamiento más empleado es la retropropagación. En el caso de la RN multicapa, el error es una complicada función compuesta de los pesos de las capas previas. La retropropagación emplea la regla de la cadena (técnica usada en cálculo diferencial) para calcular los gradientes (direcciones) del error en términos de suma de producto de gradientes locales resultante de las diferentes rutas que se pueden tomar desde un nodo hasta la salida. El algoritmo de retropropagación, es una aplicación de la programación dinámica. Esta está compuesta de dos fases, de avance y retroceso. En la primera fase, se calculan los valores de salida y las derivadas locales de varios nodos, y en la segunda fase, se acumulan los productos de estos valores locales en las rutas desde el nodo hasta la salida (Hagan et al., 2006; Neapolitan & Neapolitan, 2018).

- Fase de avance: en esta fase, las entradas para una instancia de entrenamiento, se alimentan dentro de la RN. Esto da como resultado, una cascada de cálculos hacia adelante a través de las capas, usando el conjunto de pesos actual. La salida final prevista se puede comparar con la de la etapa de entrenamiento y se calcula la derivada de la función de error con respecto a la salida. La derivada de este error ahora se calculará con respecto a los pesos en todas las capas en la fase de retroceso.
- Fase de retroceso: el principal objetivo de la fase de retroceso, es aprender el gradiente de la función de error con respecto a los diferentes pesos usando la regla de la cadena. Estos gradientes, son empleados para actualizar los pesos. De esta manera, ya que los gradientes son obtenidos de reversa (empezando en la salida) a esta etapa del entrenamiento se le conoce como etapa o fase de retroceso.

En resumen, El primer paso es propagar la entrada a través de la red hacia adelante:

$$a^0 = p \quad 2.28$$

$$a^{m+1} = f^{m+1}(W^{m+1}a^m + b^{m+1}) \text{ para } m = 0, 1, \dots, M - 1 \quad 2.29$$

$$a = a^M \quad 2.30$$

El segundo paso es propagar las sensibilidades de la red hacia atrás a través de la red:

$$s^M = -2F^M(n^M)(t - a) \quad 2.31$$

$$s^m = F^m(n^m)(W^{m+1})^T s^{m+1}, \text{ para } m = M - 1, \dots, 2, 1 \quad 2.32$$

Finalmente, los pesos y bias son actualizados:

$$W^m(k + 1) = W^m(k) - \alpha s^m (a^{m-1})^T \quad 2.33$$

$$b^m(k + 1) = b^m(k) - \alpha s^m \quad 2.34$$

Siendo α la tasa de aprendizaje, s la sensibilidad de cierta capa ante la entrada, M el número de capa, t el valor objetivo y F la función de transferencia derivativa (Hagan et al., 2006).

CAPÍTULO 3

Metodología

3.1. Metodología propuesta

A continuación, en la Figura 3.1, se muestra la metodología para el procesamiento de señales de EEG para la detección y clasificación de MI de pierna izquierda (PI) y MD.

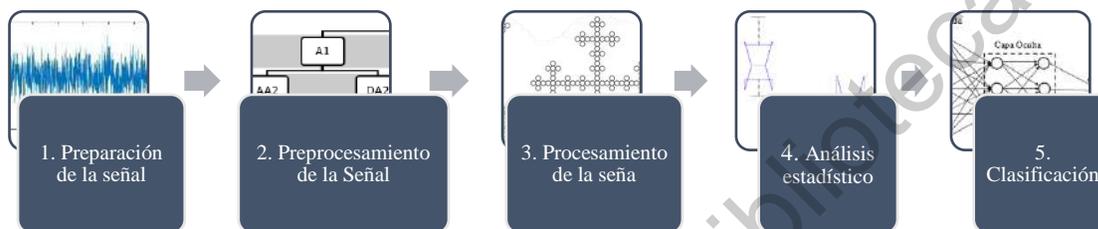


Figura3.1. Metodología propuesta.

Como se observa en la figura, la metodología propuesta consta de 5 pasos principales, que son:

- 1. Preparación de la señal.** Se realiza el acondicionamiento de la base de datos (ver sección 3.2 “Descripción de la base de datos”) que consistirá en dos partes. En la primera parte, se divide la señal de cada uno de los pacientes de la base de datos en eventos de actividad y reposo. La segunda parte consiste en dividir la señal de eventos de actividad previamente adquirida, en los diferentes tipos de movimiento que componen la señal: MD, MIz, Pierna Derecha (PD), PI, Lengua y ER. De esta manera se puede trabajar con los tipos de movimiento deseado. Se aplica el mismo proceso a las señales de todos los pacientes de la base de datos para continuar con el paso 2.
- 2. Preprocesamiento de la señal.** Para el segundo paso, se toman las señales de MI PI y de MD provenientes de los electrodos C3 y C4 de cada paciente. A estas cuatro señales de cada paciente se les aplica la WPT con un nivel de descomposición de 5 y con una Ondoleta madre Daubechies 44, para tener 32 descomposiciones. Así, se obtienen 128 señales por cada paciente para poder continuar con el proceso.

- 3. Procesamiento de la señal.** El siguiente paso, consiste en aplicar diferentes técnicas de extracción de características a las señales resultantes del paso anterior. A las señales, se les aplican métodos de FD como lo son el método Box, algoritmo de Higuchi, algoritmo de Katz y algoritmo de Sevcik; además de técnicas de entropía como el algoritmo de Shannon, método por Aproximaciones y método por Permutaciones. De esta manera se obtiene un solo valor por cada vector de WPT para todas las descomposiciones y los tipos de movimientos de ambos electrodos seleccionados. Por tanto, para cada electrodo se tienen 64 valores (32 para cada tipo de movimiento), por cada tipo de FD o entropía. De esta manera, se resaltan las características más relevantes de cada movimiento para tener parámetros discriminatorios y así clasificarlos de manera efectiva. Para poder optimizar el proceso, se agrupan los valores de todos los pacientes por tipo de movimiento, electrodo y fractalidad. Por lo que de este paso resulta un pequeño vector por cada tipo de fractalidad/entropía, electrodo, descomposición wavelet y tipo de movimiento.
- 4. Análisis estadístico.** Ahora con los datos agrupados, se evalúa estadísticamente por medio de un análisis de varianza (ANOVA) no paramétrico los mejores conjuntos de datos de fractalidad o entropía, aquí se ingresan en comparación los dos tipos de movimientos para el mismo electrodo, técnica de extracción de características y descomposición wavelet. De esta manera, se puede determinar cuáles son los datos que aportan una información más sustanciosa para discriminar entre ellos de acuerdo a su valor P. De este análisis se selecciona el mejor electrodo, tipo de extractor de características y descomposición wavelet para clasificarlo con una RN.
- 5. Clasificación.** Como paso final, y ya seleccionado el conjunto de datos con mejores resultados del ANOVA (en donde se selecciona el tipo de extractor de características para que descomposición de qué electrodo) se diseña una RN multicapa (probando diferentes cantidades de capas ocultas y números de neuronas) para que clasifique satisfactoriamente los dos diferentes tipos de movimiento. Se dividen los datos para entrenar, validar y probar la red. Posteriormente, se analizarán los resultados.

3.2. Descripción de la base de datos empleada

La base de datos empleada, llamada “A large electroencephalographic motor imagery dataset for electroencephalographic brain computer interfaces”, fue adquirida de SCIENTIFIC DATA (<https://www.nature.com/articles/sdata2018211#Sec20>) considerada de acceso público. A continuación, se describirán algunos de los aspectos más relevantes de dicha base de datos.

3.2.1. Participantes y procedimientos

La base de datos cuenta con 60 horas de grabaciones de 13 participantes, más de 60000 ejemplos de MI y 4 paradigmas diferentes. Todos los experimentos fueron aprobados por el comité de ética de la Universidad de Toros y la Universidad de Mersin en la ciudad de Mersin, Turquía. La investigación consta de 13 participantes entre las edades de 20 y 35 años, todos ellos estudiantes sanos de las universidades antes mencionadas. La muestra consta de 8 sujetos masculinos y 5 sujetos femeninos. Ninguno de ellos con presencia de condiciones psiquiátricas ni medicados o con alguna contradicción para la grabación de señales de EEG. Los sujetos serán identificados de ahora en adelante por “Sujeto A” hasta “Sujeto M”.

Cada grabación fue organizada como una secuencia de tres segmentos de interacciones de BCI de 15 minutos cada una, separadas por 2 minutos de descanso. Cada grabación consta de 2.5 minutos al inicio en donde se le mencionó al sujeto de prueba que se relajara. Durante los segmentos de actividad los sujetos realizaron más de 300 pruebas ejecutando diferentes instrucciones de MI provenientes de una interface gráfica (IG). Cada prueba comenzó con un estímulo visual en la IG, esta permaneció en la pantalla por 1 segundo durante el cual, los participantes ejecutaron el movimiento indicado una sola vez, posteriormente, se hizo una pausa de 1.5-2.5 segundos, terminando la prueba. Con todos estos segmentos de actividad y de descanso, cada grabación tiene una duración de entre 50 y 55 minutos en donde las señales de EEG fueron grabadas continuamente.

3.2.2. Adquisición de los datos

La base de datos de EEG fue adquirida haciendo uso del sistema EEG-1200 JE-921A, una estación médica de EEG usada en diversos hospitales; este cuenta con mediciones de alta precisión de EEG de hasta 38 canales. Para esta base de datos, se utilizó el sistema internacional estandarizado 10-20. Se acondicionó el cuero cabelludo de cada participante,

limpiando la superficie y midiéndola para acomodar los 22 electrodos (19 electrodos de adquisición, 2 electrodos de referencia y 1 electrodo bipolar para la sincronización de los datos), cada uno con gel conductor. Así bien, se monitorearon las impedancias para que estas fueran $<10k\Omega$ con el modo de chequeo de impedancia del sistema EEG-1200.

La señal fue adquirida a una frecuencia de muestreo de 200 Hz. Para estas señales, fue aplicada un filtro pasa bandas de 0.53-70 Hz. De igual manera, se implementó un filtro notch de 50 Hz para reducir la interferencia eléctrica del ambiente. Las sesiones fueron controladas por un software basado en Matlab y las grabaciones fueron grabadas en Neurofax en un archivo de datos de Matlab; en cada archivo de cada sujeto, se incluyen anotaciones (pequeñas etiquetas para cada muestra de la señal) del tipo de movimiento para cada instante dentro de la señal, las anotaciones para cada electrodo, la señal para cada electrodo, entre otras variables con datos relevantes. La resolución del voltaje en la base de datos exportada fue de $0.01\mu V$ a 24 bit y la frecuencia de muestreo permaneció igual que en la grabación de EEG.

3.2.3. Interacciones y paradigmas

Todos los datos grabados, forman parte de un paradigma síncrono; cada segmento experimental de BCI consiste en una serie de pruebas indicadas de manera visual al sujeto de prueba para que el cree el MI. Dentro de la base de datos existen 4 diferentes paradigmas:

- CLA: por su acrónimo en inglés, (CLA, Classical) MI clásico mano Izquierda/Derecha.
- FREEFORM: estilo libre MI de mano Izquierda/Derecha.
- 5 F: por su acrónimo en inglés, (F, Fingers) MI de 5 dedos.
- HaLT: por su acrónimo en inglés, (Ha, Hand; L, Leg; T, Tongue) MI de Mano/Pie/Lengua.

Dentro de esta tesis, se empleó el paradigma HaLT que es una extensión del paradigma CLA ya que se tienen seis estados de MI: PD, MD, PI, MIz, Lengua y ER. Para este paradigma, los participantes permanecieron viendo el punto central de la Figura 3.2.; Al inicio de cada prueba, una señal de acción indicando PI, PD, MIz, MD, L, ER (figura circular al centro de la pantalla), fue presentada por 1 segundo. Durante este segundo, los

participantes realizaron el correspondiente MI. Una vez finalizado este tiempo, los participantes permanecieron de manera pasiva hasta la siguiente señal de acción (Kaya et al., 2018).

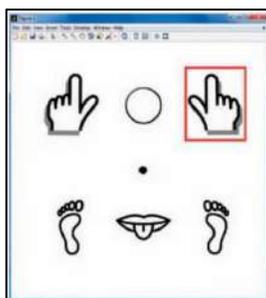


Figura 3.2. Interface gráfica del usuario para el paradigma HALT.

3.3. Validación de la metodología usando señales sintéticas

Para validar una parte de la metodología como lo es la WPT y los diferentes extractores de características como lo son las entropías o la FD, se puede optar por realizar una pequeña prueba con una señal conocida. De esta manera, es posible comprobar a pequeña escala si el método realmente hace lo que se describe en la literatura.

3.3.1. Validación de la Transformada Wavelet por Paquetes

A continuación, se validará la WPT, haciendo uso de una ondoleta madre Daubechies 44 con un nivel de descomposición de nivel 5. Para poder validar dicha técnica se debe de contar con una señal sintética (y), en este caso se optará por una función senoidal compuesta de la suma de otras dos funciones seno de 10 Hz y 150 Hz como se muestra en la Figura 3.3.

$$y_1 = \cos(2 * \pi * 10); y_2 = \cos(2 * \pi * 150); y = y_1 + y_2 \quad 3.1$$

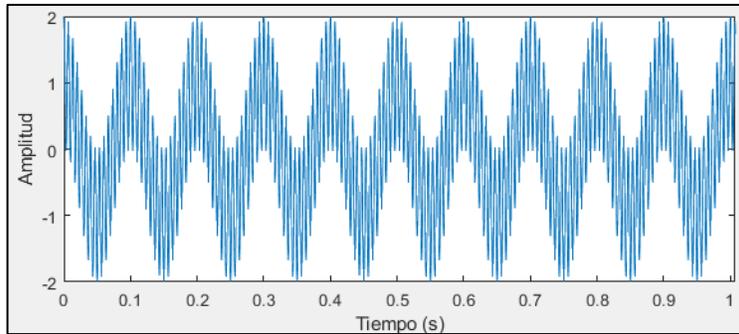


Figura 3.3. Función senoidal compuesta de 10Hz y 150Hz.

La WPT descompone la señal en un abanico de diferentes descomposiciones en dónde (en este caso al ser una función sintética) no se encuentra ninguna señal más que en algunas de ellas. Este es el caso de la descomposición número 1 y 7, Figura 3.4, en donde se puede observar que al parecer contienen información relevante. Por otro lado, En la figura 3.5 se muestra un ejemplo de una descomposición que no tiene ninguna señal.

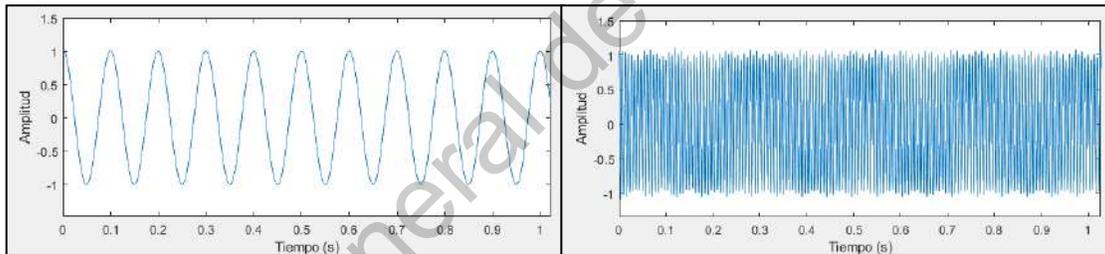


Figura 3.4. Descomposición número 1 (a la izquierda) y número 7 (a la derecha) de la WT por Paquetes de una señal sintética.

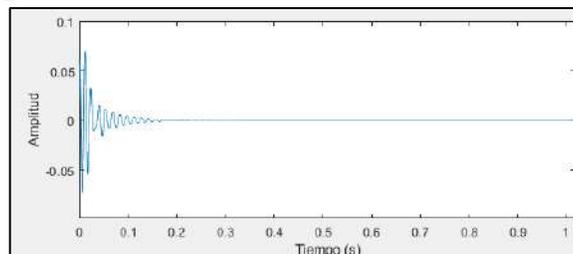


Figura 3.5. Descomposición número 4 de la WT por Paquetes para una función senoidal compuesta.

Ahora, para poder corroborar que son las frecuencias que teníamos al inicio, se procederá a aplicar la transformada rápida de Fourier; en la figura 3.6, se puede observar el resultado para dichas descomposiciones.

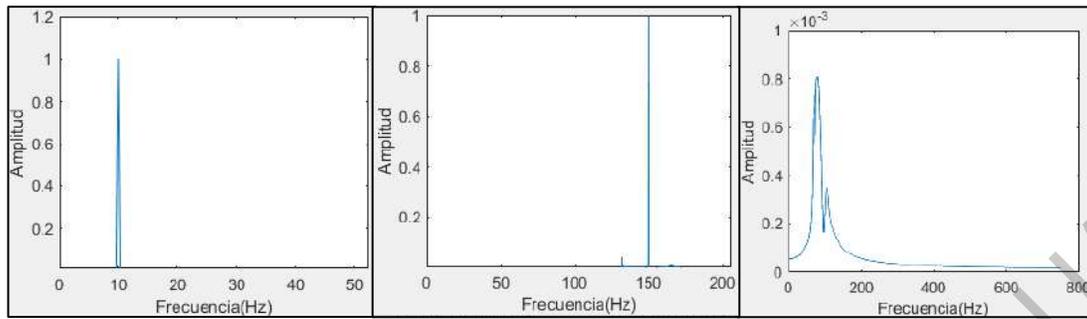


Figura 3.6. Frecuencia de 10 Hz (recuadro a la izquierda), 150 Hz (recuadro al centro) y frecuencia nula (recuadro a la izquierda) resultantes de la transformada rápida de Fourier aplicada a las descomposiciones 1, 7, y 4, respectivamente.

De la misma manera, se realiza la validación para una señal compuesta sintética, pero con ruido gaussiano inmerso en toda la señal como se presentaría en una señal más orgánica como se puede observar en la Figura 3.7.

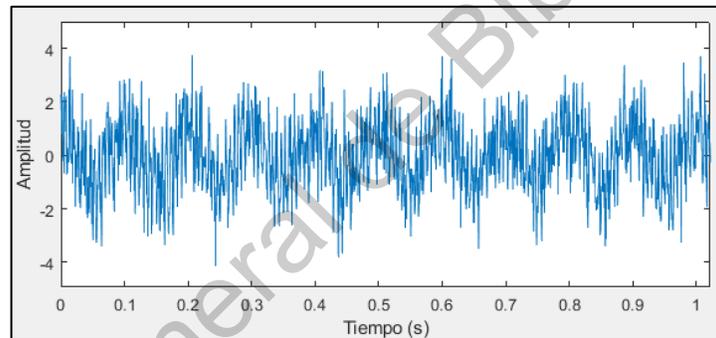


Figura 3.7. Función senoidal compuesta de 10Hz, 150Hz y ruido gaussiano.

A diferencia de las Figuras 3.4 y 3.5 se puede observar en la Figura 3.8 y 3.9 cómo la WPT analiza la señal y la divide en diferentes descomposiciones en donde todas ellas están contaminadas por el ruido gaussiano; pese a esto, aún se pueden ver ciertos niveles con información relevante. Este es el caso de la descomposición número 1 y 7 que, como ya vimos en la etapa anterior, contienen nuestras frecuencias buscadas. Por otro lado, la descomposición 4 contendrá en este caso únicamente ruido gaussiano.

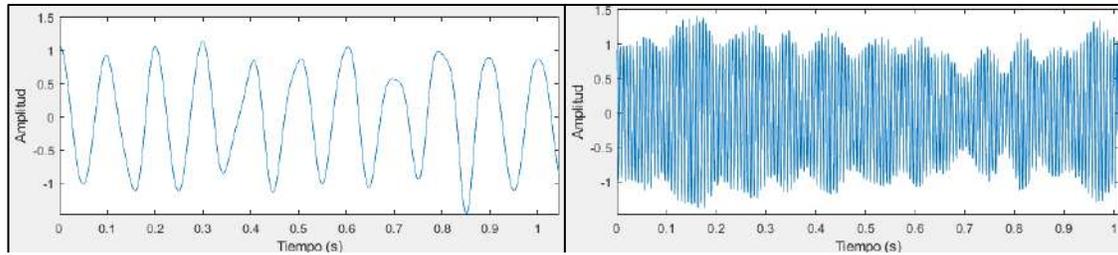


Figura 3.8. Descomposición número 1 (a la izquierda) y número 7 (a la derecha) de la WPT de una señal sintética con ruido gaussiano.

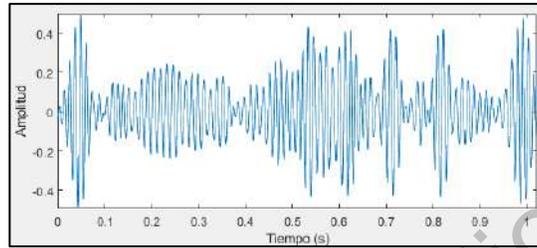


Figura 3.9. Descomposición número 4 de la WPT para una función senoidal compuesta con ruido gaussiano.

Así como en la etapa anterior, se procederá a aplicar la transformada rápida de Fourier. En la Figura 3.10 se puede observar el resultado para dichas descomposiciones. De igual manera, se eligió una descomposición al azar para analizar y comparar. En ella, se puede ver cómo no contiene información relevante, a diferencia de las otras dos descomposiciones; en las que, aunque el ruido está presente, es evidente que la señal objetivo predomina.

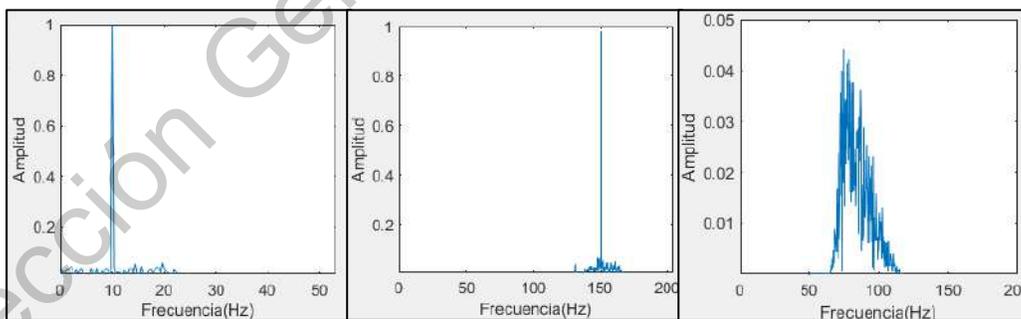


Figura 3.10. Frecuencias de 10 Hz (recuadro a la izquierda), 150 Hz (recuadro al centro) y Ruido gaussiano (recuadro a la derecha), resultantes de la transformada rápida de Fourier aplicada a la WPT.

Con el análisis previo, podemos concluir que aplicar la WPT es válido para la descomposición de señales sintéticas y, de acuerdo a la literatura previamente presentada, se corrobora que será una herramienta útil para el análisis de señales de EEG.

3.3.2. Validación de Dimensión Fractal y Entropía

A continuación, se validarán los métodos de extracción de características, BFD, HFD (con $k_{max}=32$, HFD32 y $k_{max}=64$, HFD64), SFD, KFD, Entropía de Shannon (ES), Entropía de Permutación (EP) (con $lag=3$ y $dim=2$) y Entropía de Aproximación (EA) (con $lag=3$ y $dim=2$). Para poder validar estas técnicas, se crearán 4 señales senoidales sintéticas, la primera con frecuencias de 10Hz y 30 Hz (y_3), la segunda con frecuencias de 100Hz y 150Hz (y_6) y la tercera y cuarta similares a la primera y segunda, pero con ruido gaussiano inmerso, como se puede observar en la Figura 3.11 y 3.12.

$$y_1 = \cos(2 * \pi * 10); y_2 = \cos(2 * \pi * 30); y_3 = y_1 + y_2 \quad 3.2$$

$$y_4 = \cos(2 * \pi * 100); y_5 = \cos(2 * \pi * 150); y_6 = y_4 + y_5 \quad 3.3$$

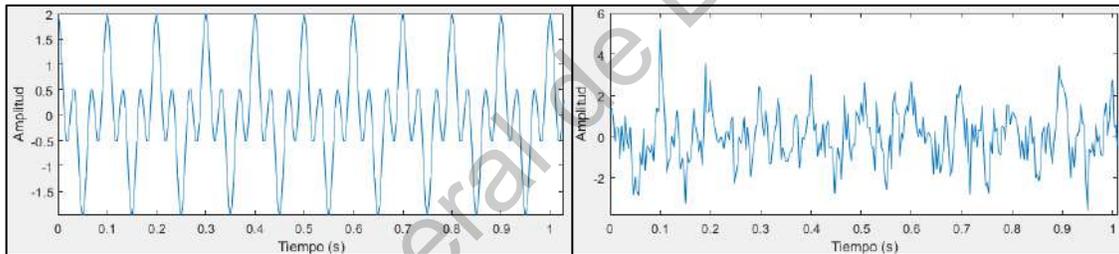


Figura 3.11. Función senoidal compuesta de 10Hz y 30Hz (recuadro a la izquierda); y Función senoidal compuesta de 10Hz, 30Hz y ruido gaussiano (recuadro a la derecha).

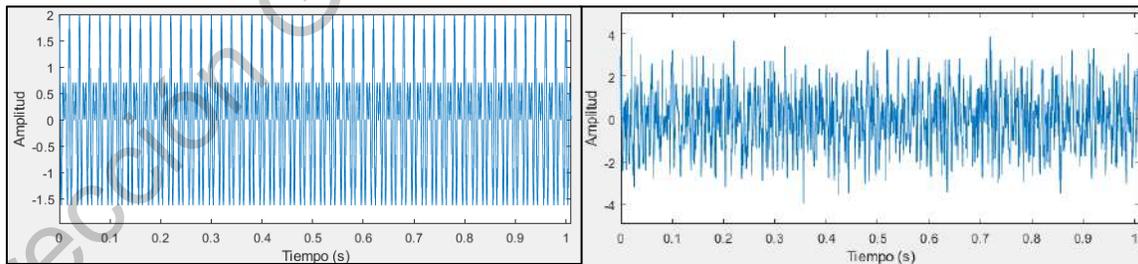


Figura 3.12. Función senoidal compuesta de 100Hz y 150Hz (recuadro a la izquierda); y Función senoidal compuesta de 100Hz, 150Hz y ruido gaussiano (recuadro a la derecha).

A cada una de estas señales se les aplicarán todas las técnicas y se compararán entre ellas, en la Tabla 3.1, en donde en cada columna está el valor de la Entropía o la FD para cada una de las señales.

Característica								
	BFD	HFD32	HFD64	KFD	SFD	AE	PE	SE
A	1.48591	3.15057	2.64488	1.39810	1.66561	0.22010	1.64285	3.73939
B	1.59960	3.10784	2.61820	1.42867	1.75029	0.26604	1.64319	3.71990
C	1.70304	1.99052	1.99850	1.42068	1.71574	1.63838	1.76606	9.49260
D	1.77886	2.01093	2.00384	1.44435	1.74777	2.00225	1.74898	10.69282

Tabla 3.1. Comparativa de valores de FD y Entropía para señales sintéticas.

Como se puede observar en la Tabla 3.1 los valores de cada técnica varían para cada tipo de señal, por lo que se puede concluir que todas las técnicas distinguen entre las diferentes características geométricas de la señal. De este modo, decir que emplear dichas técnicas es válido para la descomposición de señales sintéticas y, de acuerdo a la literatura previamente presentada, se corrobora que todas estas técnicas, serán herramientas útiles para el análisis de señales de EEG.

CAPÍTULO 4

Experimentación y Resultados

4.1. Resultados obtenidos

En el siguiente apartado se muestra a detalle la metodología puesta en práctica para la base de datos anteriormente descrita, así como los resultados que se obtuvieron en cada etapa. Cabe resaltar que, de los 13 sujetos de prueba, las señales del Sujeto D y Sujeto F fueron descartadas debido a una incompatibilidad del archivo, resultando en 11 sujetos de prueba a los cuales se les aplicó la metodología propuesta. Así mismo, la metodología se implementó dos veces del paso 1 hasta el paso 4; esto fue para tener una etapa preliminar en donde se pudiera ver cuáles eran los mejores métodos para la mitad de la base de datos y no manipular todos estos. De esta manera, se pueden hacer ajustes finos para obtener los mejores resultados posibles.

1. Preparación de la señal.

Como se mencionó anteriormente, cada señal de cada sujeto de prueba, consta de tres intervalos de actividad (con duración de 15 minutos) divididos por intervalos de descanso (de 2 minutos, para relajación y aclimatación del paciente) (Kaya et al., 2018). En esta primera etapa, se dividió la señal y las anotaciones (para saber de qué acción se trataba en cada momento) en los intervalos antes mencionados; de esta manera, se obtuvo un archivo de tipo estructura que contiene los tres intervalos de actividad, para los electrodos C3 y C4 con sus respectivas anotaciones para cada instante de tiempo. En esta primera etapa, se extrajo el intervalo central de cada uno de los participantes, para descartar los posibles errores del primer intervalo y del tercer intervalo (debido a la premura del aprendizaje de la tarea y a la fatiga de la prueba, respectivamente).

Posteriormente, y haciendo uso de las anotaciones, se separó cada intervalo (con 300 tareas variadas y combinadas) en los diferentes tipos de tareas, dando como resultado, un archivo de tipo estructura, que contiene los diferentes tipos de movimiento PI, PD, MIz, MD, L y ER para ambos electrodos seleccionados del intervalo en cuestión, terminando así el acondicionamiento de la señal. En la Figura 4.1 se puede ver un ejemplo de señal de EEG de MI de MD del electrodo C3 del Sujeto A, extraída del segundo intervalo de actividad.

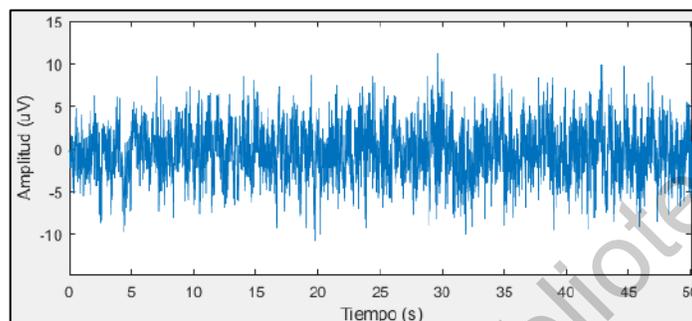


Figura 4.1. Señal de EEG para MI de MD del Sujeto A del electrodo C3.

2. Descomposición wavelet.

A cada intervalo se aplicó la WPT, con un nivel de descomposición 5, a fin de tener la mayor cantidad de bandas de frecuencia de la señal, ya que de esta manera se facilita el poder discriminar entre cambios contiguos en frecuencia. Es importante hacer notar que se seleccionó el nivel 5 ya que un nivel superior podría generar problemas de modulación, puesto que el ancho de banda obtenido es muy estrecho. Así bien, se aplicó la ondoleta madre Daubechies 44 a todas las señales resultantes que fueran de MI de PI, PD, BI y BD para ambos electrodos (C3 y C4), resultando un archivo de tipo estructura que contiene las 32 descomposiciones wavelet para cada uno de los movimientos en los diferentes electrodos para cada sujeto. En la Figura 4.2 se muestran dos de las descomposiciones wavelet para el movimiento de MIz para el electrodo C4 del sujeto M; en ésta, se puede ver cómo existen ciertas descomposiciones en las que se podría encontrar información relevante, como lo es en la descomposición 13 (imagen inferior), en comparación a otra descomposición con menos actividad (imagen superior, descomposición 12). Esto se puede inferir de manera cualitativa, pero es necesario un análisis matemático para poder decir con certeza en cual descomposición se encontrará la información más relevante.

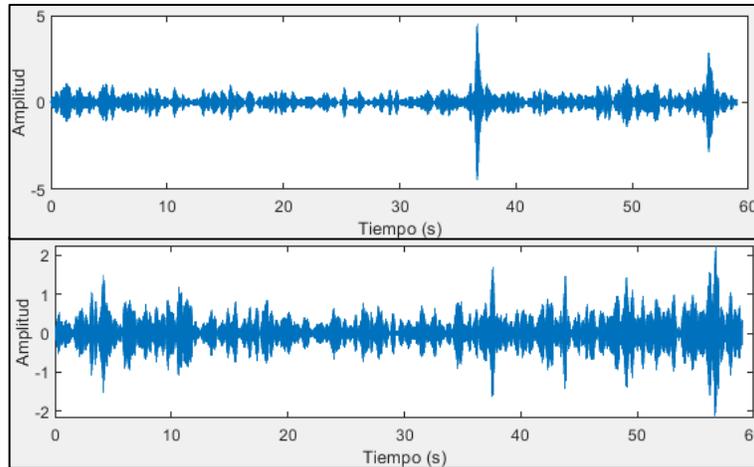


Figura 4.2. Descomposiciones Wavelet 12 (superior) y 13 (inferior) del MI de MIz del electrodo C4 del Sujeto M.

3. Procesamiento de la señal.

En este paso se calculó la FD y la Entropía de los movimientos a comparar (MD y PI) para cada una de las 32 descomposiciones wavelet para cada electrodo. De esta manera, se obtuvo un archivo de tipo estructura para cada uno de los diferentes tipos de Entropía o FD para cada sujeto. En la Tabla 4.1, se pueden observar los valores obtenidos de dichas herramientas para el Sujeto E en los electrodos C3 para el movimiento de MD en los primeros 10 de 32 nodos, a modo de ejemplo; en el último renglón de esta tabla, se puede observar el valor promedio de cada método, por lo que se puede inferir que cada uno está trabajando de manera diferente para la misma señal. Cabe mencionar que los análisis con las 8 herramientas de extracción de características sólo fueron empleadas para los primeros 5 Sujetos, posteriormente, en el ANOVA, resaltaron las tres mejores herramientas que se emplearon para todas las señales (ver “4. Análisis estadístico”).

Nodo	EA	EP	ES	BFD	HFD32	HFD64	KFD	DKS
1	0.47545	0.90703	11.0549	-1.6644	1.06365	1.20512	1.33064	1.45208
2	0.63791	1.09312	10.8065	-1.6928	1.35669	1.70430	1.36805	1.56802
3	0.63791	1.24358	10.6474	-1.6694	1.76598	1.82300	1.39001	1.60240
4	0.63791	1.37312	11.0003	-1.7587	1.79916	1.89175	1.41164	1.66296
5	0.66897	1.48819	10.4180	-1.6349	1.92451	1.90176	1.40968	1.64456
6	0.65056	1.58022	10.7123	-1.6802	1.90719	1.91780	1.40565	1.68644
7	0.72371	1.65409	10.5539	-1.6547	1.97207	1.92801	1.42907	1.69101
8	0.74306	1.70997	10.3316	-1.6513	1.93362	1.93763	1.42832	1.69221
9	0.74134	1.75437	10.1940	-1.6447	1.95969	1.93512	1.42777	1.69127
10	0.69370	1.78057	10.6701	-1.6768	1.96533	1.93867	1.44160	1.73669
Promedio	0.661052	1.458426	10.6389	-1.67279	1.764789	1.818316	1.404243	1.64276

Tabla 4.1. Valores de Entropías y Dimensiones Fractal para los primeros 10 valores de la descomposición wavelet del MI de MD del electrodo C3.

Antes de pasar al siguiente paso fue necesario acomodar todas las señales de todos los sujetos provenientes del mismo electrodo, nodo y tipo de extractor de características en un mismo vector para poder realizar el ANOVA. Así pues, se obtuvo al final de este proceso un archivo de tipo estructura en donde para cada tipo de extractor de características se agruparon los 11 Sujetos y se sub agruparon según el número de la descomposición y el electrodo. Por tanto, se obtuvieron vectores de 11 datos con información relevante para cada una de las descomposiciones (32 renglones en total por cada extractor de características). En la Tabla 4.2 se muestran los 5 primeros vectores de HFD32 del electrodo C3 para el MI de PI para 11 sujetos. Así mismo, en la Tabla 4.3 se muestran los 5 primeros vectores de HFD32 del electrodo C3 para el MI de MD para 11 sujetos. En ambas tablas se muestra en el último renglón el valor promedio para cada vector; al compararse ambas tablas en el análisis de varianza y en el diagrama de cajas y bigotes, se encontrarán los mejores vectores a comparar, aquellos que, entre otras cosas, tengan un promedio lo más diferente entre sí.

Sujeto	Vector 1	Vector 2	Vector 3	Vector 4	Vector 5
A	1.06781	1.32011	1.78484	1.82190	1.92516
B	1.06684	1.33845	1.77661	1.80416	1.92183
C	1.05327	1.31527	1.77522	1.82286	1.91705
E	1.06210	1.34446	1.78087	1.79961	1.92325
G	1.06029	1.32092	1.76945	1.81472	1.91242
H	1.05334	1.32120	1.78771	1.82560	1.91878
I	1.06034	1.30929	1.78790	1.80392	1.92414
J	1.06688	1.32946	1.77668	1.80372	1.91242
K	1.06219	1.33155	1.79358	1.79995	1.91529
L	1.07178	1.32312	1.77837	1.80099	1.91709
M	1.06048	1.33505	1.78599	1.79970	1.91900
Promedio	1.06230	1.32626	1.78156	1.80883	1.91876

Tabla 4.2. Primeros 5 vectores de HFD32 del electrodo C3 para MI de PI de 11 sujetos.

Sujeto	Vector 1	Vector 2	Vector 3	Vector 4	Vector 5
A	1.05774	1.33571	1.78215	1.81118	1.92200
B	1.06769	1.31256	1.78951	1.80351	1.91731
C	1.05007	1.32727	1.78596	1.80827	1.91465
E	1.06365	1.35669	1.76598	1.79916	1.92451
G	1.06025	1.34349	1.77651	1.80335	1.92394
H	1.05121	1.32232	1.78102	1.80723	1.92493
I	1.05870	1.31002	1.77759	1.80347	1.91909
J	1.05370	1.33811	1.78954	1.80610	1.91156
K	1.05893	1.32898	1.78709	1.79523	1.91493
L	1.07184	1.34063	1.79162	1.79771	1.91989
M	1.05247	1.33824	1.77389	1.80040	1.91957
Promedio	1.05875	1.33218	1.78189	1.80323	1.91930

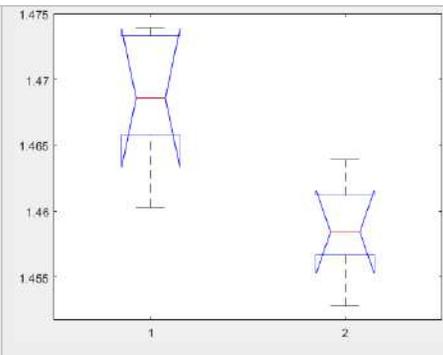
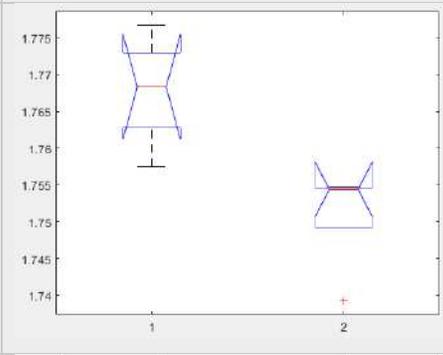
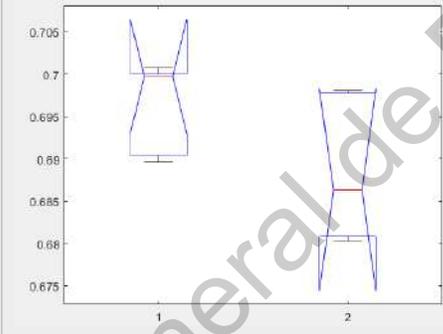
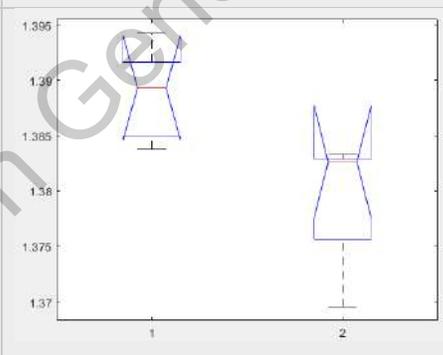
Tabla 4.3. Primeros 5 vectores de HFD32 del electrodo C3 para MI de MD de 11 sujetos.

4. Análisis estadístico.

Con los vectores anteriores obtenidos, se compararon aquellos provenientes del mismo electrodo, del mismo nivel de descomposición wavelet, con el mismo método de extracción de características, pero con diferente tipo de MI. Para realizar la comparación, se empleó el método de Kruskal-Wallis (ANOVA no paramétrico), a fin de obtener el menor valor P que se calcula entre los diferentes nodos y características. Debe recordarse que entre más cercano a 0 esté el valor P, se considera que los conjuntos de información analizados son independientes, facilitando a la RN el poder distinguir entre los diferentes tipos de MI.

De manera similar, se prestó particular atención en la distribución del diagrama de cajas y bigotes, buscando el menor traslape entre ambos tipos de MI. En la Tabla 4.4 se muestra una comparativa de los mejores diagramas de cajas y bigotes de las comparativas previamente descritas, en donde 1=PI y 2=MD, (para todas las herramientas de extracción de características), así como de sus valores P respectivos de los vectores de 5 sujetos, en estos, se puede observar algunos métodos que destacan sobre otros; tal es el caso de HFD32, SFD y ES con valores P de 0.009 y buenas distribuciones de los diagramas de cajas y bigotes.

Característica	Diagrama de cajas y bigotes	Electrodo	Nodo	Valor P
BFD		C3	2	0.0090
HFD32		C3	18	0.0090
HFD64		C4	23	0.0283

KFD		C3	26	0.0163
SFD		C3	15	0.0090
EA		C4	23	0.0758
EP		C4	4	0.0090

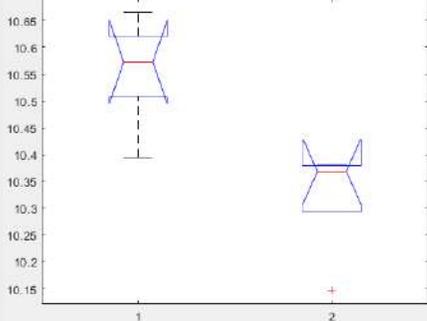
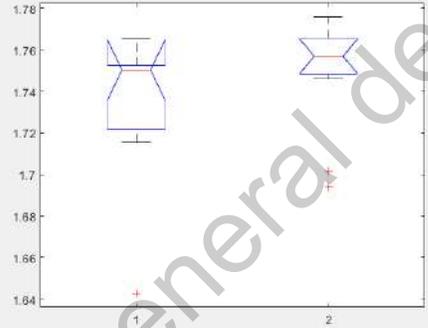
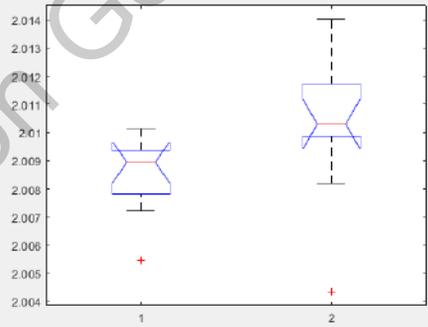
ES		C3	15	0.0090
-----------	---	-----------	-----------	---------------

Tabla 4.4. Comparativa de ANOVA para los diferentes extractores de características con vectores de 5 sujetos.

Una vez obtenida esta información, se procede ahora a analizar toda la base de datos; es decir, se implementó ahora el análisis de varianza para vectores de 11 sujetos, pero únicamente en los métodos de HFD32, SFD y ES que sobresalieron de entre los otros (como ya se mencionó anteriormente). En la tabla 4.5, se muestran los mejores resultados para estas comparativas.

Característica	Diagrama de cajas y bigotes	Electrodo	Nodo	Valor P
SFD		C3	12	0.0940
HFD32		C3	18	0.0090

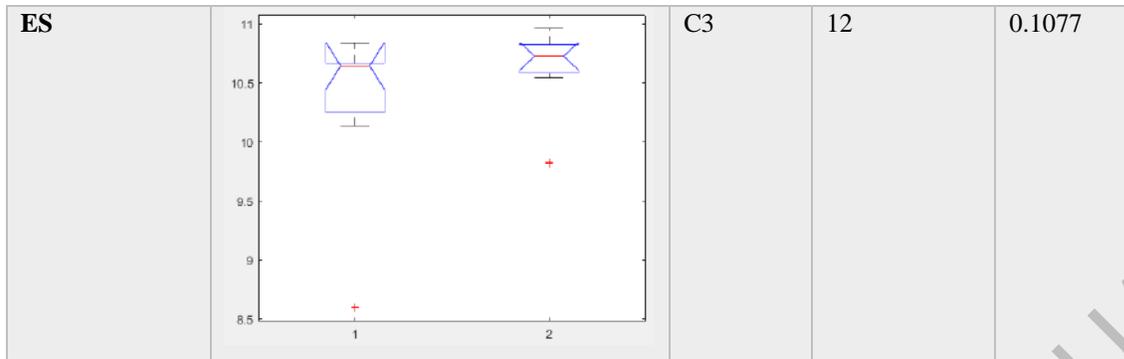


Tabla 4.5. Comparativa de ANOVA para tres diferentes extractores de características con vectores de 11 sujetos.

De acuerdo a los resultados anteriores y tomando en cuenta tanto el valor P como la distribución del diagrama de cajas y bigotes, se optó por usar el método de HFD32 para la siguiente etapa.

5. Clasificación.

Para poder continuar con la clasificación, se deben preparar los datos para que se pueda contar con datos para el entrenamiento, la validación y la prueba de la red. Así bien, se crearon dos conjuntos de datos para en entrenamiento y la validación. El primer conjunto es un vector de longitud 22 que en los primeros 11 espacios contiene a los valores de HFD32 para MI de PI y en los segundos 11 espacios a los valores de HFD32 para MI de MD; este conjunto representa a las entradas de la RN. El segundo conjunto, es una matriz de 2x22 en donde, en el primer renglón, los primeros 11 espacios, son unos y el resto ceros, y en el segundo renglón, los primeros 11 espacios son ceros y el resto son unos; este conjunto representa a los objetivos a los cuales debe de llegar la RN. De esta manera, la RN sabe que los primeros 11 valores de las entradas corresponden a PI y los segundos 11 valores corresponden a MD. De igual manera, se apartó y trató un nuevo conjunto de señales (provenientes de los intervalos de señales no empleadas previamente) para que se pudiera probar la RN con entradas nuevas. Se realizaron los mismos conjuntos previamente descritos, pero esta vez con 6 sujetos para cada movimiento en lugar de 11.

Con los datos listos para ser empleados, se diseñaron diversas redes con distinto número de neuronas en las capas ocultas, pero finalmente se optó por usar una con 20 neuronas en la capa oculta. Se aclara que para entrenar todas estas redes se usó el algoritmo del gradiente conjugado, ya que es el más eficiente entre el uso de recursos computacionales

y la exactitud del clasificador (Hagan et al., 2006). Esta RN demostró tener una exactitud del 93.8% en la etapa de entrenamiento, como muestra la matriz de confusión en la Tabla 4.6. Del mismo modo, la red mostro tener un 100% de exactitud en la etapa de validación como se puede observar en la matriz de confusión de la Tabla 4.7.

Clase de salida	PI	8	1	88.9%
		50.0%	6.3%	11.1%
	MD	0	7	100%
		0.0%	43.8%	0.0%
		100%	87.5%	93.8%
		0.0%	12.5%	6.3%
		PI	MD	
		Clase objetivo		

Tabla 4.6. Matriz de confusión de entrenamiento.

Clase de salida	PI	3	0	100%
		100.0%	0.0%	0.0%
	MD	0	0	0.0%
		0.0%	0.0%	0.0%
		100%	0.0%	100%
		0.0%	0.0%	0.0%
		PI	MD	
		Clase objetivo		

Tabla 4.7. Matriz de confusión de validación.

Posteriormente y como último paso de la metodología, se probó la RN con los datos nuevos mencionados previamente (la información de los 5 sujetos restantes); esta demostró tener un 91.7% de exactitud, como se puede ver en la Tabla 4.8.

Clase de salida	PI	6 50.0%	1 8.3%	85.7%
	MD	0 0.0%	5 41.7%	100%
		100%	83.3%	91.7%
		0.0%	16.7%	8.3%
		PI	MD	
		Clase objetivo		

Tabla 4.8. Matriz de confusión de prueba.

4.2. Discusión de resultados

Los resultados previamente mostrados obtenidos a partir de la metodología anteriormente propuesta, denotan una exactitud del 91.7% para discriminar entre MI de BD y de PI. Dicho objetivo se alcanzó haciendo uso de técnicas de baja carga computacional como lo es la WPT, por encima de otras técnicas (Lotfollahi-Yaghin & Koozdaragh, 2011; Shao & Sun, 2001). En investigaciones previas, se han clasificado diferentes señales provenientes de MI de EEG (empleando metodologías diversas), en donde las técnicas usadas demandan altos recursos computacionales. Con esto dicho, la WPT, las Entropías, La FD y la RN multicapa, demuestran ser métodos no lineales poderosos para el análisis de señales de EEG.

A continuación, en la Tabla 4.9, se muestran algunos de los resultados obtenidos por otros investigadores en años recientes para detección de MI en señales de EEG.

Autor(es)	MI	Metodología	Resultados
Rahman et al. (Rahman et al., 2019)	MI, MD, PI, PD.	<ol style="list-style-type: none"> Preparación de la señal, filtrado notch de 50Hz y Pasa bandas de 4-100Hz y separación por tareas. Reducción del tamaño de señal empleando PCA. Aplicación de WPT como extractor de características. Entrenamiento de la RN y clasificación de las señales en una RN de dos etapas. 	74.60% de exactitud de clasificación para 15 sujetos de prueba.
Miah et al. (Miah et al., 2020)	MI, MD, PI, PD	<ol style="list-style-type: none"> Preparación de la señal, aplicando un filtro de cuarto orden Butterworth para reducción de ruido. Cálculo de las matrices de covarianza de muestras promedio por medio de la desviación absoluta media como extractor de características. Selección de las características con un PCA y de un análisis de varianza. Clasificación de dichas características con un análisis lineal discriminante. 	88.5% de exactitud de clasificación para 3 sujetos de prueba.
Phang et al. (Phang & Ko, 2020)	PI, PD	<ol style="list-style-type: none"> Aplicación correlación de Pearson, modelos autorregresivos multivariados y de coherencia parcial direccional para extraer las redes de conectividad cerebral. Realización de un análisis de red compleja basada en la teoría gráfica para caracterizar la conectividad cerebral de dimensiones complejas. Elaboración uso de una SVM como clasificador. 	86.26% de exactitud de clasificación para 12 sujetos de prueba.
Tang et al. (Tang et al., 2020)	MI, MD	<ol style="list-style-type: none"> Aplicación de la descomposición empírica de modos a la señal de EEG para volverla a reconstruir a partir de los componentes intrínsecos de modo. Extracción de características a partir de una CNN de una dimensión. Clasificación a partir de una CNN multiescala de una dimensión. 	82.61% de exactitud de clasificación para 9 sujetos de prueba.
Xiao et al. (Xiao & Fang, 2021)	MI, MD, PD	<ol style="list-style-type: none"> Procesado la base de datos haciendo uso de la transformada de Fourier de tiempo corto para detectar cambios en las ondas beta cerebrales. Cálculo de la CWT Morlet. Construcción una CNN de cinco capas ocultas como clasificador. 	94.64% de exactitud de clasificación para 5 sujetos de prueba.
Mwatad et al. (Mwata-Velu et al., 2021)	MI, MD.	<ol style="list-style-type: none"> Procesado de la señal de EEG filtrándola con un filtro pasa bajas de 80Hz y un filtro rechaza bandas entre 50Hz y 60Hz. Empleo de tres redes neuronales convolucionales en cascada, aunadas a dos redes neuronales recursivas de memoria de largo/corto plazo. 	84.69% de exactitud de clasificación para 4 sujetos de prueba.

Tabla 4.9. Resumen de investigaciones de clasificación de señales de EEG de MI de extremidades.

Hay algunos puntos que se pueden resaltar de la comparativa de los datos de investigaciones de la Tabla 4.9 contra la metodología propuesta en este proyecto.

- Con la metodología propuesta en este proyecto, se obtuvo una exactitud del 91.7%. Una exactitud mejor comparada con otras investigaciones del tema en cuestión (Miah et al., 2020; Mwata-Velu et al., 2021; Phang & Ko, 2020; Rahman et al., 2019; Tang et al., 2020; Xiao & Fang, 2021).
- No fue necesario realizar un filtrado de frecuencias previo, aminorando la carga computacional (Miah et al., 2020; Mwata-Velu et al., 2021; Rahman et al., 2019).
- En esta investigación se emplearon técnicas de FD y entropías para extraer características, a diferencia de otras técnicas más elaboradas empleadas en otras investigaciones (Miah et al., 2020; Phang & Ko, 2020; Tang et al., 2020).
- Se empleó una base de datos de 11 sujetos, más extensa que en algunas de las investigaciones presentadas previamente, esto remarca la efectividad de la clasificación empleada en esta metodología (Miah et al., 2020; Mwata-Velu et al., 2021; Tang et al., 2020; Xiao & Fang, 2021).
- Se obtuvieron mejores resultados en general, en esta investigación, comparada con la investigación que empleó la misma base de datos que la empleada en este trabajo 91.7% contra 86.26% (Phang & Ko, 2020).

CAPÍTULO 5

Conclusiones y Prospectivas

5.1. Conclusiones

Las señales de EEG de MI representan un campo enorme para el análisis y el empleo en BCIs; existen diversos dispositivos y procesos en la actualidad que se podrían optimizar haciendo uso de dichas señales y de actuadores que se rijan por estas; Por esto, es importante ahondar en estos tópicos y mejorar las actuales metodologías y resultados.

En el presente trabajo de tesis, se hace uso de una base de datos de la universidad de Mersin en Turquía (Kaya et al., 2018); en esta, se recopilaron las señales de EEG de MI de 12 sujetos de prueba. Esta base de datos, fue preprocesada con la WPT, que muestra una considerable optimización del tiempo de cómputo (Shao & Sun, 2001); después, fue procesada con 7 diferentes algoritmos de FD o Entropías de las cuales se eligió el algoritmo de FD de Higuchi (con $k_{max}=32$) por sus buenos resultados en comparación con los demás métodos y reafirmando esto con la literatura revisada (Fernández Fraga & Rangel Mondragoón, 2017); posteriormente, fue analizada con un ANOVA para distinguir entre los electrodos y descomposiciones que mostraran menos similitud entre ellos; finalmente, se clasificó con una RN multicapa de 20 neuronas en la capa oculta que demostró tener una exactitud del 91.7% en la detección de MI de BD o PI en señales de EEG.

Dichos resultados, se muestran aceptables en comparación con investigaciones previas en donde la carga computacional es mayor por las técnicas de descomposición, extracción de características o clasificación empleadas; en donde la exactitud de la clasificación es menor, o bien se usaron bases de datos de menor magnitud. Por esto dicho, se considera que la metodología previamente presentada en este trabajo, así como su ejecución concluyeron de manera exitosa.

5.2. Prospectivas

Pese a los buenos resultados previamente mostrados, se tienen diversas observaciones que podrían mejorar el método o bien optimizar partes del proceso. A continuación, se enlistan algunos de estos puntos:

- Se propone realizar un filtrado de señales de electromiograma (EMG) o electrooculograma (EOG) con el fin disminuir el ruido en las señales y así poder tener una mejor extracción de características por medio de la FD o de las Entropías.
- También, se sugiere prestar especial atención al tamaño de la ventana de tiempo que se emplea para la detección de cada señal, para así poder detectar al menor estímulo si la señal está presente o no.
- Se sugiere realizar una etapa intermedia de clasificación para seleccionar de manera dinámica cual electrodo y qué descomposición wavelet usar para cada señal ya que se ha demostrado que estas pueden variar de frecuencia con relativa facilidad.

Así mismo, se proponen algunas formas de continuar esta investigación:

- Se plantea realizar un sistema de actuadores conjuntos a la salida de la RN multicapa para realizar alguna acción con las señales procesadas.
- Se propone crear un sistema en línea de BCI con la metodología propuesta para evaluar el desempeño y el tiempo de respuesta de esta red con señales que se acaban de generar.
- También, se sugiere realizar una investigación más exhaustiva para así incluir diferentes tipos de movimiento como PD, MI.

Referencias Bibliográficas

- Acharya, U. R., Fujita, H., Oh, S. L., Hagiwara, Y., Tan, J. H., & Adam, M. (2017). Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals. *Information Sciences*, 415–416, 190–198. <https://doi.org/10.1016/j.ins.2017.06.027>
- Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., Adeli, H., & Subha, D. P. (2018). Automated EEG-based screening of depression using deep convolutional neural network. *Computer Methods and Programs in Biomedicine*, 161, 103–113. <https://doi.org/10.1016/j.cmpb.2018.04.012>
- Amarantidis, L. C., & Abásolo, D. (2019). Interpretation of entropy algorithms in the context of biomedical signal analysis and their application to EEG analysis in epilepsy. *Entropy*, 21(9). <https://doi.org/10.3390/e21090840>
- Amezquita-Sanchez, J. P. (2021). Entropy algorithms for detecting incipient damage in high-rise buildings subjected to dynamic vibrations. *JVC/Journal of Vibration and Control*, 27(3–4), 426–436. <https://doi.org/10.1177/1077546320929145>
- Amin, S. U., Alsulaiman, M., Muhammad, G., Bencherif, M. A., & Hossain, M. S. (2019). Multilevel Weighted Feature Fusion Using Convolutional Neural Networks for EEG Motor Imagery Classification. *IEEE Access*, 7, 18940–18950. <https://doi.org/10.1109/ACCESS.2019.2895688>
- Andrearczyk, V., & Whelan, P. F. (2017). *Chapter 4 - Deep Learning in Texture Analysis and Its Application to Tissue Image Classification* (A. Depeursinge, O. S. Al-Kadi, & J. R. B. T.-B. T. A. Mitchell (eds.); pp. 95–129). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-812133-7.00004-1>
- Bansal, D., & Mahajan, R. (2019). EEG-Based Brain-Computer Interfacing (BCI). In *EEG-Based Brain-Computer Interfaces*. Elsevier Inc. <https://doi.org/10.1016/b978-0-12-814687-3.00002-8>
- Batres-Mendoza, P., Ibarra-Manzano, M. A., Guerra-Hernandez, E. I., Almanza-Ojeda, D. L., Montoro-Sanjose, C. R., Romero-Troncoso, R. J., & Rostro-Gonzalez, H. (2017). Improving EEG-based motor imagery classification for real-time applications using the QSA method. *Computational Intelligence and Neuroscience*, 2017. <https://doi.org/10.1155/2017/9817305>
- Batres-Mendoza, P., Montoro-Sanjose, C. R., Guerra-Hernandez, E. I., Almanza-Ojeda, D. L., Rostro-Gonzalez, H., Romero-Troncoso, R. J., & Ibarra-Manzano, M. A. (2016). Quaternion-based signal analysis for motor imagery classification from electroencephalographic signals. *Sensors (Switzerland)*, 16(3). <https://doi.org/10.3390/s16030336>
- Bialy, H. (1989). The fractal geometry of the heart. In *Nature Biotechnology* (Vol. 7, Issue 12). <https://doi.org/10.1038/nbt1289-1219>
- Burns, A., Adeli, H., & Buford, J. A. (2020). Upper Limb Movement Classification Via Electromyographic Signals and an Enhanced Probabilistic Network. *Journal of Medical Systems*, 44(10), 57–59. <https://doi.org/10.1007/s10916-020-01639-x>
- Casas, I. (2020). Networks, Neural. In *International Encyclopedia of Human Geography* (Second Edi, Vol. 9). Elsevier. <https://doi.org/10.1016/b978-0-08-102295-5.10410-x>

- Castro Guzman, G. E., Balardin, J. B., Biazoli, C. E., Sato, J. R., & Fujita, A. (2019). Network analysis of neuropsychiatry disorders. *Precision Medicine for Investigators, Practitioners and Providers*, 397–408. <https://doi.org/10.1016/B978-0-12-819178-1.00039-3>
- Chen, X., Wang, Y., & Gao, X. (2008). High-speed steady-state visual evoked potential-based brain-computer interfaces. In P. B. T.-S. W. and B.-C. I. Diez (Ed.), *Smart Wheelchairs and Brain-Computer Interfaces* (pp. 111–130). Elsevier. <https://doi.org/10.1016/B978-0-12-812892-3.00006-6>
- Chui, C. K., & Mhaskar, H. N. (2016). Signal decomposition and analysis via extraction of frequencies Dedicated to Professor Ranko Bojanic on the occasion of his 90th birthday. *Applied and Computational Harmonic Analysis*, 40(1), 97–136. <https://doi.org/10.1016/j.acha.2015.01.003>
- Cooper, C. (2013). Hand Therapy for Chemotherapy-Induced Peripheral Neuropathy. In *Fundamentals of Hand Therapy: Clinical Reasoning and Treatment Guidelines for Common Diagnoses of the Upper Extremity: Second Edition* (Second Edi). Elsevier Inc. <https://doi.org/10.1016/B978-0-323-09104-6.00041-9>
- Cruz Ramírez, H. (2018). *Metodología basada en la Descomposición Empírica de Modos Completa y Fractales para la Clasificación de Imaginación Motora usando Señales Electroencefalográficas*. Universidad Autónoma de Querétaro.
- D’Croz-Baron, D., Ramirez, J. M., Baker, M., Alarcon-Aquino, V., & Carrera, O. (2012). A BCI motor imagery experiment based on parametric feature extraction and Fisher Criterion. *CONIELECOMP 2012 - 22nd International Conference on Electronics Communications and Computing*, 257–261. <https://doi.org/10.1109/CONIELECOMP.2012.6189920>
- Dauphiné, A. (2017). Statistical and Probability Models for Given Relationships Between Societies and the Natural Environment. *Geographical Models with Mathematica*, 19–72. <https://doi.org/10.1016/b978-1-78548-225-0.50003-8>
- Davies, E. R. (2018). *Chapter 15 - Deep-learning networks* (E. R. B. T.-C. V. (Fifth E. Davies (ed.); pp. 453–493). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-809284-2.00015-0>
- Donald, D. A., Everingham, Y. L., McKinna, L. W., & Coomans, D. (2009). Feature Selection in the Wavelet Domain: Adaptive Wavelets. *Comprehensive Chemometrics*, 3, 647–679. <https://doi.org/10.1016/B978-044452701-1.00033-8>
- Espinosa-Paredes, G. (2021). Nonlinear BWR dynamics with a fractional reduced order model. In *Fractional-Order Models for Nuclear Reactor Analysis* (Vol. 9). <https://doi.org/10.1016/b978-0-12-823665-9.00007-9>
- Ewins, D. J. (2001). MODAL ANALYSIS, EXPERIMENTAL | Basic Principles. *Encyclopedia of Vibration*, 805–813. <https://doi.org/10.1006/rwvb.2001.0026>
- Fernández Fraga, S., & Rangel Mondragoón, J. (2017). Comparativo de los Algoritmos de Dimensión Fractal Higuchi, Katz y Multiresolución de Conteo de Cajas en Señales EEG Basadas en Potenciales Relacionados por Eventos. *Revista EIA*, 14(27), 73–83. <https://doi.org/10.24050/reia.v14i27.864>
- Gandhi, V. (2015). Interfacing Brain and Machine. *Brain-Computer Interfacing for Assistive Robotics*, 7–63. <https://doi.org/10.1016/b978-0-12-801543-8.00002-8>
- George, S. H., Rafiei, M. H., Borstad, A., Adeli, H., & Gauthier, L. V. (2017). Gross motor ability

predicts response to upper extremity rehabilitation in chronic stroke. *Behavioural Brain Research*, 333, 314–322. <https://doi.org/https://doi.org/10.1016/j.bbr.2017.07.002>

Georgopoulos, A. P. (1997). Chapter 13 Motor cortex: Neural and computational studies. In *Advances in Psychology* (Vol. 121, Issue C). Elsevier Masson SAS. [https://doi.org/10.1016/S0166-4115\(97\)80099-4](https://doi.org/10.1016/S0166-4115(97)80099-4)

Guanghai Dai, Jun Zhou, Jiahui Huang, N. W. (2020). HS-CNN: A CNN with hybrid convolution scale for EEG motor imagery classification. *Journal of Neural Engineering*, 17, <https://doi.org/10.1088/1361-6463/aad7de>. <https://doi.org/https://doi.org/10.1088/1741-2552/ab405f>

Gustitus, D. (2017). Common Orthopedic Dysfunction of the Wrist and Hand. In *Orthopaedic Physical Therapy Secrets: Third Edition* (3rd ed.). Elsevier Inc. <https://doi.org/10.1016/B978-0-323-28683-1.00051-5>

Hagan, M. T., Demuth, H. B., & Hudson, M. (2006). Neural networks in a softcomputing framework. *Neural Networks in a Softcomputing Framework*, 1–566. <https://doi.org/10.1007/1-84628-303-5>

Hazarika, N. (1997). Nonlinear considerations in EEG signal classification. *IEEE Transactions on Signal Processing*, 45(4), 829–836. <https://doi.org/10.1109/78.564171>

Higuchi, T. (1988). Approach To an Irregular Time Series on the Basis of the Fractal Theory. *Physica D: Nonlinear Phenomena*, 31(2), 277–283.

Hong, D., Wang, J., & Gardner, R. (2005). Chapter 9 - Wavelets in Signal Processing (D. Hong, J. Wang, & R. B. T.-R. A. with an I. to W. and A. Gardner (eds.); pp. 315–352). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-012354861-0/50009-9>

INEGI. (2017). *La discapacidad en México, datos al 2014*.

Jaffery, Z. A., & Islamia, J. M. (2014). ECG Baseline Drift Elimination Using Wavelet Packets Transform. *Australian Journal of Basic and Applied Sciences*, July, 459–466.

Katz, M. J. (1988). Fractals and the analysis of waveforms. *Computers in Biology and Medicine*, 18(3), 145–156. [https://doi.org/10.1016/0010-4825\(88\)90041-8](https://doi.org/10.1016/0010-4825(88)90041-8)

Kaya, M., Binli, M. K., Ozbay, E., Yanar, H., & Mishchenko, Y. (2018). Data descriptor: A large electroencephalographic motor imagery dataset for electroencephalographic brain computer interfaces. *Scientific Data*, 5(November), 1–16. <https://doi.org/10.1038/sdata.2018.211>

Keenan, S. A., Carrillo, O., & Casseres, H. (2013). Electroencephalography. *Encyclopedia of Sleep*, 66–70. <https://doi.org/10.1016/B978-0-12-378610-4.00140-6>

Kehtarnavaz, N. (2008). Frequency Domain Processing. *Digital Signal Processing System Design*, 1, 175–196. <https://doi.org/10.1016/b978-0-12-374490-6.00007-6>

Khan, J., Bhatti, M. H., Khan, U. G., & Iqbal, R. (2019). Multiclass EEG motor-imagery classification with sub-band common spatial patterns. *Eurasip Journal on Wireless Communications and Networking*, 2019(1). <https://doi.org/10.1186/s13638-019-1497-y>

Khorshidtalab, A., Salami, M. J. E., & Hamed, M. (2012). Evaluation of time-domain features for motor imagery movements using FCM and SVM. *JCSSE 2012 - 9th International Joint Conference on Computer Science and Software Engineering*, 17–22. <https://doi.org/10.1109/JCSSE.2012.6261918>

- Li, J., Zhang, X., Gong, J., Tang, J., Ren, Z., Li, G., Deng, Y., & Cai, J. (2018). SIGNAL-NOISE IDENTIFICATION of MAGNETOTELLURIC SIGNALS USING FRACTAL-ENTROPY and CLUSTERING ALGORITHM for TARGETED DE-NOISING. *Fractals*, 26(2), 1–18. <https://doi.org/10.1142/S0218348X1840011X>
- Liu, Y. H., Huang, S., & Huang, Y. De. (2017). Motor imagery EEG classification for patients witamyotrophic lateral sclerosis using fractal dimension and Fisher's criterion-based channel selection. *Sensors (Switzerland)*, 17(7). <https://doi.org/10.3390/s17071557>
- Lotfollahi-Yaghin, M. A., & Koozdaragh, M. (2011). Examining the function of wavelet packet transform (WPT) and continues wavelet transform (CWT) in recognizing the crack specification. *KSCE Journal of Civil Engineering*, 15(3), 497–506. <https://doi.org/10.1007/s12205-011-0925-2>
- Louis, E., Frey, L., Britton, J., Hopp, J., Korb, P., Koubeissi, M., Lievens, W., & Pestana-Knight, E. (2016). Electroencephalography (EEG): An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants. In *Electroencephalography (EEG): An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants*. <https://doi.org/10.5698/978-0-9979756-0-4>
- MacIntyre, T. E., Madan, C. R., Moran, A. P., Collet, C., & Guillot, A. (2018). Motor imagery, performance and motor rehabilitation. In *Progress in Brain Research* (1st ed., Vol. 240). Elsevier B.V. <https://doi.org/10.1016/bs.pbr.2018.09.010>
- Mahmood, A., Bennamoun, M., An, S., Soheli, F., Boussaid, F., Hovey, R., Kendrick, G., & Fisher, R. B. (2017). Chapter 21 - Deep Learning for Coral Classification (P. Samui, S. Sekhar, & V. E. B. T.-H. of N. C. Balas (eds.); pp. 383–401). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-811318-9.00021-1>
- Medina, B., Sierra, J. E., & Ulloa, A. B. (2018). Técnicas de extracción de características de señales EEG en la imaginación de movimiento para sistemas BCI Extraction techniques of EEG signals characteristics in motion imagination for BCI systems. *Espacios*, 39(22), 36–48. <https://www.revistaespacios.com/a18v39n22/18392236.html>
- Mehler, D. M. A., Williams, A. N., Krause, F., Lührs, M., Wise, R. G., Turner, D. L., Linden, D. E. J., & Whittaker, J. R. (2019). The BOLD response in primary motor cortex and supplementary motor area during kinesthetic motor imagery based graded fMRI neurofeedback. *NeuroImage*, 184(August 2018), 36–44. <https://doi.org/10.1016/j.neuroimage.2018.09.007>
- Miah, A. S. M., Rahim, M. A., & Shin, J. (2020). Motor-imagery classification using riemannian geometry with median absolute deviation. *Electronics (Switzerland)*, 9(10), 1–11. <https://doi.org/10.3390/electronics9101584>
- Michael-Titus, A., Revest, P., & Shortland, P. (2010). Clinical Examination. *The Nervous System*, 47–58. <https://doi.org/10.1016/b978-0-7020-3373-5.00003-4>
- Mitrović, D., Zeppelzauer, M., & Breiteneder, C. (2010). Features for Content-Based Audio Retrieval. *Advances in Computers*, 78(10), 71–150. [https://doi.org/10.1016/S0065-2458\(10\)78003-7](https://doi.org/10.1016/S0065-2458(10)78003-7)
- Murugappan, M., Boon, H., Raj, A. N. J., Krishnan, G., & Karthikeyan, P. (2020). ECG Morphological Features Based Sudden Cardiac Arrest (SCA) Prediction Using Nonlinear Classifiers. *Advances in Electrical and Computer Technologies*, 672. https://doi.org/https://doi.org/10.1007/978-981-15-5558-9_68

- Mwata-Velu, T., Ruiz-Pinales, J., Rostro-Gonzalez, H., Ibarra-Manzano, M. A., Cruz-Duarte, J. M., & Avina-Cervantes, J. G. (2021). Motor imagery classification based on a recurrent-convolutional architecture to control a hexapod robot. *Mathematics*, 9(6), 1–15. <https://doi.org/10.3390/math9060606>
- Mwema, F. M., Akinlabi, E. T., Oladijo, O. P., Fatoba, O. S., Akinlabi, S. A., & Tălu, S. (2020). Advances in manufacturing analysis: fractal theory in modern manufacturing. *Modern Manufacturing Processes*, 13–39. <https://doi.org/10.1016/b978-0-12-819496-6.00002-6>
- Namazi, H., & Ala, T. S. (2019). Decoding of simple and compound limb motor imagery movements by fractal analysis of electroencephalogram (EEG) signal. *Fractals*, 27(3), 1–8. <https://doi.org/10.1142/S0218348X19500415>
- Natarajan, K., Acharya, U. R., Alias, F., Tiboleng, T., & Puthusserypady, S. K. (2004). Nonlinear analysis of EEG signals at different mental states. *BioMedical Engineering Online*, 3, 1–11. <https://doi.org/10.1186/1475-925X-3-7>
- Neapolitan, R. E., & Neapolitan, R. E. (2018). Neural Networks and Deep Learning. In *Artificial Intelligence*. <https://doi.org/10.1201/b22400-15>
- Nikookar, H. (2013). Theory of wavelets. *Wavelet Radio*, 11–34. <https://doi.org/10.1017/cbo9781139084697.003>
- OIT, UNESCO, & OMS. (2005). *RBC Estrategia para la rehabilitación, la igualdad de oportunidades, la reducción de la pobreza y la integración social de las personas con discapacidad: documento de posición conjunta*. http://apps.who.int/iris/bitstream/10665/43126/1/9243592386_spa.pdf
- Olivas-Padilla, B. E., & Chacon-Murguia, M. I. (2019). Classification of multiple motor imagery using deep convolutional neural networks and spatial filters. *Applied Soft Computing Journal*, 75, 461–472. <https://doi.org/10.1016/j.asoc.2018.11.031>
- Olivas-Padilla, B. E., Chacon-Murguia, M. I., & Ramirez-Quintana, J. A. (2017). Multiclass motor imagery classification based on the correlation of pattern images generated by spatial filters. *2017 14th International Conference on Electrical Engineering, Computing Science and Automatic Control, CCE 2017*. <https://doi.org/10.1109/ICEEE.2017.8108835>
- Olofsen, E., Sleight, J. W., & Dahan, A. (2008). Permutation entropy of the electroencephalogram: A measure of anaesthetic drug effect. *British Journal of Anaesthesia*, 101(6), 810–821. <https://doi.org/10.1093/bja/aen290>
- Ortiz-Echeverri, C. J., Salazar-Colores, S., Rodríguez-Reséndiz, J., & Gómez-Loenzo, R. A. (2019). A new approach for motor imagery classification based on sorted blind source separation, continuous wavelet transform, and convolutional neural network. *Sensors (Switzerland)*, 19(20), 1–14. <https://doi.org/10.3390/s19204541>
- Penm, J., Chaar, B., Moles, R., & Penm, J. (2013). Predicting ASX Health Care Stock Index Movements After the Recent Financial Crisis Using Patterned Neural Networks. In *Rethinking Valuation and Pricing Models*. Elsevier Inc. <https://doi.org/10.1016/B978-0-12-415875-7.00037-3>
- Pérez Sánchez, A. V. (2019). *Metodología basada en la transformada wavelet y fractales para la detección anticipada de eventos epilépticos*. Universidad Autónoma de Querétaro.
- Phang, C. R., & Ko, L. W. (2020). Global Cortical Network Distinguishes Motor Imagination of the Left and Right Foot. *IEEE Access*, 8, 103734–103745.

<https://doi.org/10.1109/ACCESS.2020.2999133>

- Piña-Vega, R., Valtierra-Rodriguez, M., Perez-Ramirez, C. A., & Amezquita-Sanchez, J. P. (2021). Early prediction of sudden cardiac death using fractal dimension and ECG signals. *Fractals*, 1–13. <https://doi.org/10.1142/S0218348X21500778>
- Rafiee, J., Rafiee, M. A., Prause, N., & Schoen, M. P. (2011). Wavelet basis functions in biomedical signal processing. *Expert Systems with Applications*, 38(5), 6190–6201. <https://doi.org/10.1016/j.eswa.2010.11.050>
- Rahman, M. A., Khanam, F., Hossain, M. K., Alam, M. K., & Ahmad, M. (2019). Four-class motor imagery EEG signal classification using PCA, wavelet and two-stage neural network. *International Journal of Advanced Computer Science and Applications*, 10(5), 481–490. <https://doi.org/10.14569/ijacsa.2019.0100562>
- Rioul, O., & Vetterli, M. (1991). Wavelets and Signal Processing. *IEEE Signal Processing Magazine*, 8(4), 14–38. <https://doi.org/10.1109/79.91217>
- Rong, Y. (2020). Classification of motor imagery electroencephalography signals using continuous small convolutional neural network. *Imaging Systems and Technology*, December 2019, 1–7. <https://doi.org/10.1002/ima.22405>
- Salazar Guerrero, M. A. (2018). *CLASIFICACIÓN DE LA IMAGINACIÓN MOTORA A PARTIR DE SEÑALES EEG EMPLEANDO LA TRANSFORMADA DE DESCOMPOSICIÓN EMPÍRICA DE MODOS Y ENTROPÍA*. Universidad Autónoma de Querétaro.
- Schalk, G., Mcfarland, D. J., Hinterberger, T., Birbaumer, N., Wolpaw, J. R., & Technology, A. B. I. B. C. I. (2004). *BCI2000: A General-Purpose Brain-Computer Interface (BCI) System*. 51(6), 1034–1043.
- Scherer, R., & Vidaurre, C. (2018). Chapter 8 - Motor imagery based brain-computer interfaces. In *Chiral Analysis* (Second Edi). Elsevier B.V. <https://doi.org/10.1016/B978-0-12-812892-3/00008-X>
- Shannon, C. E. (1948). A Mathematical Theory of Communication. *Bell System Technical Journal*, 27(3), 379–423. <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>
- Shao, X., & Sun, L. (2001). An application of the continuous wavelet transform to resolution of multicomponent overlapping analytical signals. *Analytical Letters*, 34(2), 267–280. <https://doi.org/10.1081/AL-100001578>
- Siam, A. I., Sedik, A., El-Shafai, W., Elazm, A. A., El-Bahnasawy, N. A., El Banby, G. M., Khalaf, A. A. M., & Abd El-Samie, F. E. (2021). Biosignal classification for human identification based on convolutional neural networks. *International Journal of Communication Systems*, 34(7), 1–22. <https://doi.org/10.1002/dac.4685>
- Snyder, V. . A., & Vázquez, M. A. (2005). *STRUCTURE*. Elsevier Ltd, 54–68.
- Srinivasan, R., & Nunez, P. L. (2012). Electroencephalography. *Encyclopedia of Human Behavior: Second Edition*, 15–23. <https://doi.org/10.1016/B978-0-12-375000-6.00395-5>
- Tang, X., Li, W., Li, X., Ma, W., & Dang, X. (2020). Motor imagery EEG recognition based on conditional optimization empirical mode decomposition and multi-scale convolutional neural network. *Expert Systems with Applications*, 149, 113285. <https://doi.org/10.1016/j.eswa.2020.113285>

- Teo, W.-P., White, D., & Macpherson, H. (2018). Using noninvasive methods to drive brain-computer interface (BCI): the role of electroencephalography and functional near-infrared spectroscopy in BCI. In P. B. T.-S. W. and B.-C. I. Diez (Ed.), *Smart Wheelchairs and Brain-Computer Interfaces* (pp. 33–63). Elsevier. <https://doi.org/10.1016/B978-0-12-812892-3.00003-0>
- Teuwen, J., & Moriakov, N. (2020). *Chapter 20 - Convolutional neural networks* (S. K. Zhou, D. Rueckert, & G. B. T.-H. of M. I. C. and C. A. I. Fichtinger (eds.); pp. 481–501). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-816176-0.00025-9>
- Tuller, M., & Or, D. (2004). Water Retention and Characteristic Curve. *Encyclopedia of Soils in the Environment*, 4, 278–289. <https://doi.org/10.1016/B0-12-348530-4/00376-3>
- Vega, R., Sajed, T., Mathewson, K. W., Khare, K., Pilarski, P. M., Greiner, R., Sanchez-Ante, G., & Antelis, J. M. (2016). Assessment of feature selection and classification methods for recognizing motor imagery tasks from electroencephalographic signals. *Artificial Intelligence Research*, 6(1), 37–51. <https://doi.org/10.5430/air.v6n1p37>
- Williams, K., & Guarino, A. (2018). Complex Regional Pain Syndrome. *Essentials of Pain Medicine*. <https://doi.org/10.1016/B978-0-323-40196-8.00027-9>
- Xiao, X., & Fang, Y. (2021). Motor Imagery EEG Signal Recognition Using Deep Convolution Neural Network. *Frontiers in Neuroscience*, 15(March), 1–11. <https://doi.org/10.3389/fnins.2021.655599>
- Zhang, R., Zong, Q., Dou, L., & Zhao, X. (2019). A novel hybrid deep learning scheme for four-class motor imagery classification. *Journal of Neural Engineering*, 16(6), 066004. <https://doi.org/10.1088/1741-2552/ab3471>