

**DETECCIÓN AUTOMÁTICA DE CONVULSIONES EPILÉPTICAS  
USANDO ESTRATEGIAS DE APRENDIZAJE PROFUNDO Y  
ANALÍTICA PREDICTIVA**



CESAR LEANDRO DORADO ROMERO

Trabajo de Grado. Maestría en Automática

**Director:**

Ph.D Maximiliano Bueno López

Universidad del Cauca

**Codirectora:**

Ph.D. Jenny Alexandra Cifuentes Quintero

Universidad Pontificia Comillas

Universidad del Cauca

Facultad de Ingeniería Electrónica y Telecomunicaciones

Maestría en Automática

Popayán, diciembre de 2023

CESAR LEANDRO DORADO ROMERO

DETECCIÓN AUTOMÁTICA DE CONVULSIONES EPILÉPTICAS  
USANDO ESTRATEGIAS DE APRENDIZAJE PROFUNDO Y  
ANALÍTICA PREDICTIVA

Trabajo de grado presentado a la Facultad de Ingeniería  
Electrónica y Telecomunicaciones de la  
Universidad del Cauca para la obtención del  
título de  
Magíster en Automática

Director:

Ph.D Maximiliano Bueno López

Codirectora:

Ph.D. Jenny Alexandra Cifuentes Quintero

Popayán

2023

# Tabla de contenido

<b>Resumen</b>	<b>2</b>
<b>Abstract</b>	<b>3</b>
<b>Índice de Figuras</b>	<b>5</b>
<b>Índice de Tablas</b>	<b>6</b>
<b>1. Introducción</b>	<b>6</b>
1.1. Planteamiento del Problema . . . . .	9
1.2. Estado del Arte . . . . .	10
1.3. Antecedentes de la Investigación . . . . .	14
1.4. Objetivos . . . . .	19
<b>2. Revisión de la Literatura</b>	<b>21</b>
2.1. Transformada de Fourier (TF) . . . . .	21
2.2. Transformada Wavelet (TW) . . . . .	23
2.3. Descomposición Empírica de Modos (EMD) . . . . .	25
2.4. Transformada de Hilbert (TH) . . . . .	25
2.5. Transformada de Hilbert Huang (HHT) . . . . .	26
2.6. Machine Learning (ML) . . . . .	28
2.7. Deep Learning (DL) . . . . .	30
2.8. Redes Neuronales Artificiales (ANNs) . . . . .	31
<b>3. Metodología de la Investigación</b>	<b>38</b>
3.1. Elección de la Base de Datos . . . . .	38
3.2. Pre-procesamiento de la Base de Datos . . . . .	41
3.3. Clasificación de convulsiones epilépticas mediante una red neuronal artificial	43
3.4. Organización de la base de datos . . . . .	54
3.5. Evaluación del modelo de la red neuronal . . . . .	55

3.6. Descomposición de Señales . . . . .	61
3.7. Clasificación de convulsiones epilépticas con la base de datos actualizada . . . . .	63
<b>4. Presentación de Resultados</b>	<b>66</b>
4.1. Descomposición de señales empleando EMD . . . . .	66
4.2. Selección de variables a partir del análisis realizado con el EMD . . . . .	72
4.3. Clasificación automática de señales epilépticas a partir del uso de redes neurales artificiales . . . . .	75
<b>5. Discusión de los Resultados</b>	<b>81</b>
5.1. Primer entrenamiento de la red neuronal . . . . .	81
5.2. Descomposición de señales . . . . .	81
5.3. Selección de variables fundamentales para la clasificación de señales . . . . .	84
5.4. Clasificación de señales . . . . .	86
<b>6. Conclusiones</b>	<b>92</b>
6.1. Futuros trabajos . . . . .	93
<b>7. Bibliografía</b>	<b>94</b>
<b>8. Anexos</b>	<b>110</b>

# Resumen

En este trabajo de investigación, se propone un procedimiento metodológico para la detección de convulsiones epilépticas a partir de una base de datos pública. Este enfoque metodológico busca integrar un método de análisis de señales no lineales y no estacionarias con un clasificador de señales, con el objetivo de alcanzar la respuesta más efectiva para los propósitos de la investigación.

La metodología presentada se distingue por su capacidad para descomponer las señales originales, implementando un proceso de filtrado natural que resulta en señales más puras. Estas señales refinadas se utilizan como entrada para el clasificador, generando métricas de precisión, sensibilidad y especificidad. Estas métricas proporcionan una evaluación detallada del rendimiento de la metodología propuesta.

En pos de este objetivo, se llevan a cabo diversas iteraciones utilizando una base de datos depurada en el clasificador. Este enfoque iterativo contribuye a afinar y optimizar la capacidad del clasificador para discernir patrones asociados a convulsiones epilépticas, mejorando así la confiabilidad y la efectividad del procedimiento en su conjunto.

La combinación de un enfoque de descomposición de señales con un clasificador estratégicamente diseñado representa una aproximación novedosa y prometedora para la detección de convulsiones epilépticas. El énfasis en la obtención de métricas de rendimiento detalladas subraya la rigurosidad y la eficacia de la metodología, proporcionando una evaluación exhaustiva de su capacidad para abordar la problemática específica de la detección de convulsiones epilépticas en datos biomédicos.

# Abstract

In this research work, a methodological procedure for detection of epileptic seizures from a public database is proposed. This methodological approach seeks to integrate a nonlinear and non-stationary signal analysis method with a signal classifier, to achieve the most effective response for the research purposes.

The methodology presented is distinguished by its ability to decompose the original signals, implementing a natural filtering process that results in purer signals. These refined signals are used as input to the classifier, generating accuracy, sensitivity, and specificity metrics. These metrics provide a detailed performance evaluation of the proposed methodology.

In the pursuit of this objective, multiple iterations are conducted utilizing an enhanced database within the classifier. This iterative process aids in refining and optimizing the classifier's capability to identify patterns associated with epileptic seizures, thereby enhancing the overall reliability and effectiveness of the procedure.

The integration of a signal decomposition approach with a strategically designed classifier represents a novel and promising approach to epileptic seizure detection. The emphasis on obtaining detailed performance metrics underscores the rigor and efficacy of the methodology, providing a comprehensive assessment of its ability to address the specific problem of epileptic seizure detection in biomedical data.

## Índice de figuras

1.	Diagrama de flujo de EMD. . . . .	27
2.	Diagrama de una red neuronal artificial básica . . . . .	33
3.	Neurona con 3 entradas y 1 salida . . . . .	34
4.	Función de activación lineal . . . . .	34
5.	Función escalón unitario . . . . .	35
6.	Función sigmoideal . . . . .	36
7.	Función tangente hiperbólica . . . . .	36
8.	Función de activación ReLu . . . . .	37
9.	Página web de Physionet . . . . .	39
10.	Ubicación de electrodos de acuerdo al International 10-20 System . . . . .	40
11.	Dimensiones de vectores de entrenamiento y validación . . . . .	49
12.	Dimensiones de estructuras de entrenamiento y validación . . . . .	51
13.	Modelo de pérdida usando 16 neuronas . . . . .	57
14.	Modelo de exactitud usando 16 neuronas . . . . .	57
15.	Matriz de confusión obtenida después del entrenamiento de la red neuronal . . . . .	57
16.	Resultados de entrenamiento de la red neuronal usando 32 neuronas . . . . .	59
17.	Resultados de entrenamiento de la red neuronal usando 64 neuronas . . . . .	60
18.	Resultados de entrenamiento de la red neuronal usando 128 neuronas . . . . .	61
19.	Diagrama de bloques de la configuración de una red neuronal . . . . .	65
20.	Señal original de diferentes pacientes. . . . .	68
21.	Análisis de señal obtenidas con el EMD. . . . .	69
22.	Análisis de señales usando EEMD . . . . .	71
23.	IMFs obtenidas de un paciente con epilepsia . . . . .	73
24.	IFs obtenidas de un paciente con epilepsia . . . . .	74
25.	Valores de accuracy variando hiperparámetros . . . . .	87
26.	Valores de sensibilidad variando hiperparámetros . . . . .	87

27.	Valores de especificidad variando hiperparámetros . . . . .	88
28.	Accuracy con capa Bidirectional LSTM . . . . .	89
29.	Sensibity con capa Bidirectional LSTM . . . . .	90
30.	Specificity con capa Bidirectional LSTM . . . . .	90

## Índice de tablas

1.	Bandas de frecuencia características en el cerebro . . . . .	8
2.	Ubicación de los electrodos según el método International 10-20 System . .	41
3.	Librerías usadas en el software de clasificación de señales . . . . .	45
4.	Modelos implementados en la red neuronal . . . . .	45
5.	Configuración del conjunto de entrenamiento y validación . . . . .	47
6.	Valores asignados a los hiper-parámetros de la red neuronal . . . . .	53
7.	Hiperparámetros modificados para el entrenamiento de la red neuronal . .	58
8.	Información de la base de datos . . . . .	67
9.	Resultados de entrenamiento de la red neuronal usando IMFs normalizadas	78
10.	Resultados de entrenamiento de la red neuronal adicionando capa BiDirec- tional LSTM . . . . .	78
11.	Valores antiguos y actuales de la base de datos después del sobremuestreo .	80
12.	Resultados de entrenamiento de la red neuronal variando hiperparámetros	82

# 1. Introducción

La electroencefalografía es un método de monitoreo electrofisiológico que mide la actividad eléctrica generada por el desarrollo de tareas sincronizadas de miles de neuronas del cerebro [1], conectado a través de electrodos ubicados en el cráneo y cuero cabelludo de un paciente, usando métodos invasivos y no invasivos. Este método es usado con frecuencia para el diagnóstico y tratamiento de diferentes enfermedades como epilepsia [2], somnipatia, coma, encefalopatias, entre otras [3],[4]. La primera grabación neurofisiológica fue realizada por Richard Caton en el año de 1875, cuando presentó los resultados de los fenómenos eléctricos del cerebro en conejos y simios [2]. Más adelante, en el año de 1924, Hans Berger grabó la primer electroencefalografía realizada en humanos [5].

Un electroencefalograma (EEG) es una grabación de las señales eléctricas producidas en el cerebro, que muestran resultados reflejados en cambios de voltaje y frecuencia y son útiles para evaluar las enfermedades cerebrales y la actividad convulsiva de un paciente [6],[7]. Estas técnicas se convierten en importantes herramientas para el desarrollo de pruebas neuropsicológicas mas prevalentes. El progreso de métodos para el análisis de señales electroencefalográficas ha abierto una ventana al estudio de esta área, teniendo un potencial analítico que aún no ha sido explotado completamente [8], [9], [10].

La epilepsia es un desorden crónico neurológico común, caracterizado frecuentemente por ataques no provocados en el cerebro [11], que afecta aproximadamente al 1 % de la población mundial [12], [13], [14]. A nivel nacional, hasta el año 2015, la epilepsia era responsable de 0.88 % de las muertes, incluyendo las personas que mueren en estatus epiléptico y las que mueren con heridas debido a esta enfermedad [15]. Estos ataques generalmente ocurren debido a la actividad sincrónica anormal de las neuronas corticales [16], causados por una ráfaga repentina de actividad eléctrica en el cerebro [17]. En este contexto, la detección de la epilepsia es uno de los mayores retos para la neurociencia y es un tema que está en constante evolución [17], [18]. Es así como los métodos tradicionales de detección han involucrado un constante monitoreo de la actividad neuronal a través de las señales EEG, las cuales se han convertido en la técnica más aceptada por médicos para el

diagnóstico de epilepsia por su facilidad de generación, bajo costo y excelente resolución temporal [12], [19].

El análisis de señales EEG ha sido uno de los mayores temas de estudio para apoyar la detección de esta patología. Diferentes pruebas de diagnóstico para convulsiones epilépticas han sido desarrolladas como lo son: imágenes por resonancia magnética (MRI), electroencefalografías (EEG), magnetoencefalografías (MEG) y tomografía por emisión de positrones (PET) [20], [21],[22]. Principalmente en el diagnóstico clínico, detectar la epilepsia requiere de un análisis de grabaciones electroencefalográficas realizado por experimentados neurofisiólogos, los cuales pueden detectar patrones característicos de las actividades cerebrales [23]. Sin embargo, debido a la naturaleza espontánea de las convulsiones epilépticas, se necesitan las grabaciones EEG continuas y de larga duración de los pacientes, pues se ha determinado que el propósito principal de realizarlas, es registrar estas convulsiones sin previo aviso [24]. Debido a lo anterior, los resultados de las grabaciones EEG pueden ser prolongados, haciendo su análisis muy costoso e ineficiente, convirtiéndolo en un proceso que demanda tiempo y que depende de la interpretación de especialistas muy bien entrenados [11], [25].

Las bandas de frecuencia características de la actividad cerebral son fundamentales en la detección de convulsiones epilépticas y se requiere para su correcta detección análisis de las grabaciones EEG [26], [27]. Los primeros estudios realizados por Berger establecieron la definición de ondas alfa (8-13 Hz) asociados con un estado despierto pero relajado de los ojos cerrados, así como las ondas beta (13-30 Hz) asociado con la atención y la actividad [28]. La tabla 1 muestra los principales rangos de frecuencia asociados a actividades cerebrales. Los métodos tradicionales para el análisis y extracción de características de señales EEG, tales como transformada de Fourier o Wavelet [29], han tenido un buen desempeño en este campo pero tienen la desventaja de no considerar la no linealidad y no estacionariedad de este tipo de señales [30].

Con el fin de mejorar la resolución tiempo-frecuencia en el análisis de señales EEG, la Descomposición Empírica de Modos (EMD por sus siglas en inglés), ha emergido como

Tabla 1: Bandas de frecuencia características en el cerebro

<b>Banda</b>	<b>Frecuencia [Hz]</b>
<b>Deltha</b>	<b>0.1 - 3.5</b>
<b>Theta</b>	<b>4.0 - 7.5</b>
<b>Alpha</b>	<b>8.0 - 13.0</b>
<b>Betha</b>	<b>13.0 - 30.0</b>
<b>Gamma</b>	<b>&gt;30.0</b>

una valiosa alternativa [31], [32], [33]. La correcta detección de componentes frecuenciales que resultan de un EEG se convierten en la principal información para entrenar un clasificador capaz de distinguir entre convulsiones epilépticas y no epilépticas [34]. Las restricciones de los métodos de análisis convencionales de EEG en el dominio de la frecuencia y usualmente fundamentados en la transformada de Fourier, son susceptibles a variaciones en patrones de convulsiones debido a la naturaleza no estacionaria y no lineal de las señales provenientes de bases de datos [35], [36].

Las redes neuronales convolucionales son una de las más populares técnicas de aprendizaje profundo donde la mayoría de investigaciones en aprendizaje automático se ha dedicado a estudiarlas, las cuales son diseñadas para procesar datos que principalmente se encuentran en forma de múltiples arreglos [37], [38]. Inicialmente fueron usadas para aplicaciones de procesamiento de imágenes y en la actualidad su campo de acción se ha expandido hasta los sistemas de distribución eléctrica [38]. Recientemente, el diagnóstico y predicción de enfermedades usando señales biológicas ha sido otro de los campos que ha explorado este tipo de redes [39]. Esta clase de redes de aprendizaje profundo son ampliamente usada para la detección de convulsiones epilépticas a partir de señales EEG [40] como también para resolver numerosos problemas de visión por computador como lo son segmentación de imágenes, clasificación de imágenes médicas y reconocimiento facial, entre otras aplicaciones [41].

En el desarrollo de este proyecto se presentará una contribución en el área de clasificación de señales EEG para detectar convulsiones epilépticas haciendo uso de redes neuronales artificiales como método de clasificación y utilizando descomposición empírica de modos

(EMD), base de la transformada de Hilbert Huang, para encontrar las correctas bandas de frecuencias que se reconocerán con facilidad en las funciones de modo intrínseco (IMFs).

## 1.1. Planteamiento del Problema

La detección de la epilepsia es uno de los mayores retos para la neurociencia y es un tema que está en constante evolución [42], [17], [18]. Su detección consiste en un monitoreo continuo de la actividad neuronal analizando señales EEG, por medio de técnicas para el reconocimiento de patrones [43], como los métodos estadísticos, análisis predictivo y procesamiento de imágenes [12], [19]. Este análisis es fundamental porque permite descubrir componentes de frecuencia propios de dicha patología, los cuales son la base para extraer y clasificar las señales generadas por la EEG.

Los sistemas de diagnóstico de enfermedades neurodegenerativas presentan características clave que permiten al sistema actuar de una forma eficiente y práctica. De esta manera, usando señales electroencefalográficas (EEG) es posible realizar un diagnóstico de enfermedades neurodegenerativas, tales como: Parkinson, Alzheimer, Huntington, Epilepsia, Esclerosis lateral amiotrófica y demencia con cuerpos de Lewy [44], [45]. Para cada uno de los sistemas de diagnóstico lo ideal es obtener rápida y eficientemente los resultados, que su sensibilidad sea alta, al igual que su especificidad y confiabilidad.

Estos métodos tienen diferentes grados de complejidad dependiendo si el análisis se realiza en el dominio del tiempo, de la frecuencia o una combinación de estos (tiempo-frecuencia), o de las características lineales o no lineales de los procesos a analizar [46]. Las recientes investigaciones muestran que los resultados obtenidos de un paciente no son instantáneos [1], [46], esto debido a que la clasificación de las señales producidas es difícil de procesar, principalmente debido a que no se tiene una base de datos que permita determinar y examinar resultados [47], como también indicadores que muestren qué resultado es el generado pues no sabe a qué patología se refiere lo obtenido [24]. Por otro lado, los sistemas de diagnóstico requieren de una alta sensibilidad para mejorar las señales generadas, además de reducir el ruido resultante pero que a la vez no sea eliminado de los resultados

primordiales [11], [25], [48]. Este procedimiento es fundamental porque se va a descubrir información oculta en gran cantidad de datos que surgen de los resultados obtenidos, del mismo modo, se puede realizar un reconocimiento de enfermedades dependiendo de las frecuencias generadas mediante el examen realizado [26], [28]. También es posible clasificar las señales y poder determinar una patología específica.

El presente trabajo de grado presentará una contribución en el área de clasificación y descomposición de señales electroencefalográficas. Se empleará la Transformada de Hilbert Huang que considera el comportamiento no lineal y no estacionario de las señales EEG, las redes neuronales artificiales y la analítica predictiva para poder descubrir la información oculta que generan los resultados obtenidos del análisis de señales electroencefalográficas.

Basado en lo anteriormente descrito se plantea la siguiente pregunta de investigación:

¿Cuáles deben ser las características de un método automatizado para detección de convulsiones epilépticas utilizando redes neuronales profundas y descomposición empírica de modos?

## **1.2. Estado del Arte**

En este apartado del documento se muestran una serie de investigaciones realizadas durante los últimos años y que se ocupan de dar diferentes soluciones a temas de interés que abarca el presente trabajo de grado, de la misma manera se muestra cuales son los métodos mas utilizados en la actualidad para analizar señales EEG. Las subsecciones de las cuales está compuesta la revisión se enuncian a continuación:

- Métodos de descomposición lineales de señales EEG
- Métodos de descomposición no lineales de señales EEG
- Métodos de clasificación de señales EEG

Investigaciones realizadas en años anteriores se han enfocado en realizar diagnóstico de convulsiones epilépticas haciendo análisis electroencefalográfico y han sido reportados frecuentemente en la literatura usando métodos de procesamiento y clasificación de señales

[33]. Publicaciones como [3] exponen que realizar un análisis manual de datos EEG requiere de un alto entrenamiento clínico, donde el procesamiento de información se convierte en un método costoso en términos de tiempo y eficacia. Expresan que el análisis automático de datos EEG ofrece el potencial para mejorar la calidad de la atención reduciendo tanto el tiempo de diagnóstico como el error manual. De este modo proponen la arquitectura de una red neuronal recurrente (RNN) la cual está desarrollada para la clasificación de imágenes, además de ser diseñada para trabajar eficientemente con datos EEG.

Debido a la simplicidad y eficiencia, la electroencefalografía ha sido ampliamente usada en investigaciones relacionadas con la epilepsia. Las señales EEG durante eventos epilépticos muestran diferentes patrones que reflejan una excesiva actividad neuronal. Sin embargo, el proceso de monitoreo a menudo requiere demasiado tiempo, es dispendioso y depende de una inspección visual. Para situaciones como esta, en [49] se plantea como objetivo desarrollar un método de extracción de características basado en los Parámetros de Hjorth, definidas como métricas de propiedades estadísticas de señales en el dominio del tiempo e interpretando los resultados en el dominio de la frecuencia [50]. Estas métricas son: Actividad, Movilidad y Complejidad. Se estimó la movilidad por diferenciación del dominio del tiempo y fue transformada al dominio de la frecuencia usando la transformada rápida de Fourier.

El estudio propuesto en [51] propone un método automático de detección de convulsiones epilépticas basado en características Wavelet y usando clasificadores lineales para el análisis de señales EEG. El desempeño de estos clasificadores fue determinado en términos de la especificidad, sensibilidad y precisión. En este estudio, confirman al igual que en [3] y [49] que un completo análisis de señales EEG es difícil de llevar a cabo, ya que se convierte en un proceso ineficiente que conlleva a errores en el resultado final. Asumen que el análisis de la señal generada debe realizarse por medio de la transformada Wavelet, pues es la herramienta más efectiva para el análisis en el dominio del tiempo. Adicionalmente, [52] expresa que el monitoreo de convulsiones epilépticas frecuentemente necesita de un largo y dispendioso periodo de tiempo para coleccionar los extensos resultados generados. Sin embargo, no todo ese conjunto de datos contribuyen al análisis de la señal. Como

resultado de lo anterior, se deben extraer las principales señales para el procesamiento y modelamiento de datos EEG. Para ello, diferentes métodos de extracción de características se emplean y la descomposición "frecuencia-tiempo" ha sido recientemente usada para la detección de convulsiones epilépticas. Particularmente, la transformada Wavelet es aplicada con frecuencia para estimar la densidad de señales, remoción de datos irrelevantes y caracterización de convulsiones. Lo anterior demuestra que el análisis mediante Wavelet de señales EEG es una técnica ampliamente usada para detección de la epilepsia.

En [53] los autores muestran una metodología basada en la transformada de Fourier y para ello descomponen la señal EEG en un número finito de funciones de banda intrínseca con el fin de extraer características relevantes usando un test estadístico, el cual determina si un conjunto de datos provienen de una misma señal que sea de interés en el análisis. Finalmente las características significativas son analizadas y clasificadas por una máquina de soporte vectorial obteniendo resultados de confiabilidad por encima del 95 %. Del mismo modo, en [54] proponen un método de clasificación basado en la transformada de Fourier y el modelo de Markov asumiendo que los resultados obtenidos de la EEG son lineales. En [55], al igual que en los artículos citados anteriormente, utilizan la transformada de Fourier como método de clasificación de señales EEG para generar imágenes desde el conjunto de datos de entrada.

Los artículos mencionados hasta el momento muestran la metodología aplicada cuando se analizan señales EEG. Sin embargo, estos documentos asumen que las señales asociadas a exámenes EEG son lineales y usan métodos como la transformada de Wavelet y de Fourier para la descomposición de señales. En la siguiente subsección se muestra un conjunto de documentos donde se asume que las señales no son lineales y por tal motivo la metodología usada en las referencias presentadas anteriormente va a ser diferente a la planteada por los autores de [3], [33] y [53].

Hasta ahora, un gran número de investigaciones han analizado las señales EEG con el objetivo de encontrar características fundamentales del sistema cerebral. Considerando las interacciones complejas entre diferentes estructuras y regiones del cerebro, la red cere-

bral ha recibido demasiada atención y se han hecho grandes progresos en la investigación de mecanismos cerebrales [56]. La extracción de características y aprendizaje profundo han proporcionado una efectiva y factible solución para resolver problemas complejos de clasificación, incluida la investigación del estado cerebral. En [56] los autores revisan la aplicación de esas dos teorías en investigaciones de señales EEG, principalmente incluyendo la interfaz cerebro-computador, desórdenes neurológicos y análisis cognitivo. Variados algoritmos de aprendizaje automático han sido desarrollados usando diferentes métodos estadísticos, señales en el dominio de la frecuencia y parámetros no lineales para detectar convulsiones epilépticas. Entre estas estrategias, la descomposición empírica de modos (EMD) aparece como una muy buena alternativa. Básicamente es una técnica para descomponer una señal no lineal y no estacionaria en modos oscilatorios llamados funciones de modo intrínseco (IMFs) [57]. La transformada Wavelet discreta es otra alternativa para el análisis de señales no estacionarias aunque sus niveles de descomposición no tiene la misma claridad en resolución que los obtenidos con la EMD [58]. Estos métodos han sido usados satisfactoriamente en la detección o clasificación de convulsiones epilépticas como se muestra en [59], donde descomponen una señal dada en un número finito de oscilaciones de media-cero (IMDs). De este modo, se proponen en [60] nuevas características para la clasificación de convulsiones epilépticas basados en señales en 2D y 3D. En la metodología propuesta aplican EMD a una señal EEG para descomponerla posteriormente en términos de señales IMFs.

En [61] asumen que las señales EEG son no estacionarias y para ello emplean una metodología basada en EMD. Para ello, los autores proponen un método de procesamiento de señales EEG que combine los coeficientes de correlación, se analizan empleando EMD y SVM, y posteriormente se extraen y clasifican las características de convulsiones epilépticas obtenidas mediante bases de datos. Del mismo modo, en [62] proponen realizar análisis mediante EMD para posteriormente desarrollar una clasificación mediante una red neuronal artificial. En [63] confirman la metodología propuesta por [61] y [62] donde analizan características no lineales de la señal las cuales son consideradas como un conjunto de componentes de frecuencia de amplitud y frecuencia modulada (AM-FM) para posterior-

mente generar señales de sub-banda. Los autores obtienen mayor precisión de clasificación usando EMD y transformada Wavelet en conjunto.

Se observa diferentes investigaciones que se han llevado a cabo usando medidas en el dominio del tiempo y de la frecuencia y se muestra su efectividad identificando focos epilépticos asumiendo que los métodos lineales pueden ser efectivos en el análisis de señales EEG. Sin embargo, los métodos en el dominio de la frecuencia fallan cuando se requiere una muy eficiente resolución temporal [64]. Para ello, varios métodos fueron presentados para cubrir esta problemática. Como se mencionó anteriormente surge la transformada Wavelet y transformada de Fourier que son útiles para detectar señales EEG en convulsiones epilépticas. Sin embargo, estos métodos lineales convencionales no capturaban información mas allá de los primeros instantes de tiempo donde se detectan convulsiones epilépticas. Por otro lado, el análisis de métodos no lineales como EMD, podrían proporcionar información mas allá de estos instantes.

En [65] confirman la detección de diferentes métodos para el rastreo de convulsiones y también asumen que se debe seleccionar un clasificador para reconocer las diferentes señales resultantes. En este caso, las señales originales basadas en el dominio del tiempo o de la frecuencia fueron directamente analizadas desde una red neuronal convolucional para extraer todo tipo de características y su objetivo no fue solamente el detectar escenarios de epilepsia sino también verificar la capacidad del clasificador para ordenar periodos de crisis convulsivas. En [66] se muestran diferentes contribuciones con respecto a los métodos de clasificación para generar una estructura eficiente de aprendizaje profundo. En primer medida proponen una red neuronal profunda compuesta de dos capas convoluciones para extraer características de señales EEG y después tres capas completamente conectadas para la clasificación de las señales.

### **1.3. Antecedentes de la Investigación**

La detección de la epilepsia en los últimos años ha dado una evolución en la forma en la que se está siendo diagnosticada. Empezando por las grabaciones de las actividades

electroencefalográficas y analizadas por expertos neurólogos durante largos periodos de tiempo, puede llegar a generar una inadecuada interpretación de los resultados debido al enorme conjunto de datos que deben ser procesados para dar una respuesta. De allí que se ha venido evolucionando para realizar la detección automática de la epilepsia a partir de las grabaciones electroencefalográficas. En ese sentido, [67] realiza un estudio donde la detección automática de convulsiones juega un papel importante en el diagnóstico de la epilepsia.

El objetivo del documento se basa en proponer un nuevo método de detección de convulsiones combinando un método de descomposición de señales como lo es EMD con un patrón espacial común (CSP). Los autores consideran emplear Transformada Wavelet (WT) y EMD para realizar un procesamiento previo en la descomposición de las señales para luego llevarlo a una Máquina de Soporte Vectorial (SVM) el cual es utilizado como un clasificador. También analizan el progreso de la detección automática de convulsiones en las décadas anteriores donde las señales EEG basadas en el dominio del tiempo y en el dominio de la frecuencia han sido propuestas satisfactoriamente [68], [69]. Los resultados del documento revelan que utilizando la metodología propuesta es posible mejorar satisfactoriamente la sensibilidad y la especificidad lo que proporciona una herramienta útil para aplicaciones clínicas.

El trabajo propuesto y mostrado en [67], representa el desarrollo adecuado de un proceso de investigación, en la cual la metodología puede ser adaptada a otros métodos de análisis de señales basado en características tanto lineales como no lineales acoplado con un clasificador donde permita extraer los resultados eficientes y que sean validados mediante indicadores de desempeño previamente propuestos. El documento establece como conclusión que el modelo propuesto para la detección automática de convulsiones genera resultados eficientes basados en indicadores y analizados mediante dos bases de datos representando un algoritmo óptimo para el desarrollo de una metodología donde el análisis de señales es el objetivo a resolver.

El procesamiento de señales y métodos de aprendizaje como Machine Learning son he-

ramientas valiosas en el análisis de señales EEG ya que se ha venido desarrollando hasta la actualidad para diagnosticar convulsiones y ataques epilépticos. Las investigaciones realizadas para contribuir al desarrollo de esta problemática involucra métodos de descomposición de señales en diferentes modos de aprendizaje las cuales pueden proporcionar ventajas sobre otros métodos. La Transformada de Fourier es uno de los métodos de análisis de señales frecuentemente utilizado para interpretar señales a partir de un conjunto de datos. Otro método de análisis y descomposición de señales es la Descomposición Empírica de Modos la cual analiza las señales como datos no lineales y no estacionarios.

La investigación realizada por [70] permite extraer un conjunto de características a partir de las señales originales de dos conjuntos de datos para ser analizadas mediante la Transformada de Fourier y EMD con el fin de clasificar y evaluar las señales EEG. Los autores plantean una metodología para comparar el comportamiento de los métodos de análisis de señales con el uso de clasificadores para obtener características específicas en el dominio del tiempo.

Los autores expresan que es de gran interés mostrar en el documento, el método de EMD y posteriormente extraer las funciones de modo intrínseco (IMFs) definidas por los componentes de amplitud modulada (AM) y frecuencia modulada (FM). Las señales complejas no lineales y no estacionarias pueden ser descompuestas en un número finito de IMFs en el espectro de la Transformada de Hilbert. Los autores presentan los diferentes modos de descomposición que puede tener la EMD. Diferentes clasificadores son entrenados y evaluados con el fin de validar la mejor metodología.

La investigación propuesta por [70] establece como conclusión que el desarrollo de la extracción de características y el método de clasificación es un paso clave para la comprensión de la epilepsia así como los mecanismos de funcionamiento de esta, incluyendo el análisis clínico y las aplicaciones de detección y predicción de convulsiones epilépticas.

Para seguir desarrollando técnicas de aprendizaje con el fin de diagnosticar eficiente y automáticamente convulsiones y ataques epilépticos, los algoritmos basados en Machine Learning encuentran disponibles sistemas automatizados que facilitan el aprendizaje de

patrones electroencefalográficos para identificar la actividad neuronal. El estudio de estos patrones incluyen eventos relevantes que pueden dar solución a parámetros de interés basados en el tiempo, frecuencia o métodos no lineales [71], [72].

El desarrollo de una metodología para descubrir convulsiones y ataques epilépticos a partir de un conjunto de datos ha llevado a diferentes autores a analizar por medio de diferentes técnicas, la identificación y el tipo de convulsión, la cual puede ser focal o general y ubicando tanto la detección como la ubicación de la convulsión. El desarrollo propuesto por los autores de [72] se basa en realizar una revisión de dos técnicas de descomposición de señales las cuales muestran el proceso a realizar para clasificar convulsiones epilépticas. En este caso, la recopilación realizada en [72] tiene como objetivo brindar un acercamiento a las diferentes técnicas de descomposición de señales. En ese sentido, el documento abarca 19 artículos de los cuales 13 de ellos consideran realizar un mismo diagrama de bloques para realizar el proceso de clasificación de convulsiones epilépticas [73], [74], [75]. Este diagrama está compuesto principalmente realizando compilación de datos EEG, hacer un preprocesamiento de ellos para posteriormente realizar una depuración con el fin de eliminar algún dato que no pertenezca a ese grupo. A partir de esa depuración, se descompone la señal y se extraen características principales para llevarlo a un clasificador por medio de técnicas de Machine Learning.

La investigación realizada en [72] cubre una serie de bases de datos que son usadas para la extracción de la información dentro de los cuales se encuentran principalmente del Centro de epilepsia del Hospital Universitario de Freiburg en Alemania y del Children Hospital Boston MIT [76], [77], [78]. Los dos métodos de descomposición usados en la revisión de [72] son la Transformada Wavelet y EMD los cuales procesan las señales con el fin de extraer o clasificar las características.

Estos métodos de extracción de características de acuerdo a los diferentes artículos presentes en [72] son únicos para todos los estudios de la revisión. De esta manera los clasificadores están basados en la energía, estadísticas básicas o en histogramas. Para los extractores basados en energía, en [79] dividen las señales EEG en pequeños paquetes. A partir de

ello aplican FFT a las señales. Los componentes de frecuencia fueron encontrados a partir del error cuadrático medio.

Los estudios de clasificación de convulsiones epilépticas se están reportando frecuentemente en la literatura y en la actualidad se están usando diferentes métodos de clasificación para procesar señales a partir de características no lineales que son estudiadas para mejorar el rendimiento de detección y clasificación. Varios estudios presentados en la literatura emplean la TW y sus variantes para lograr la mejor clasificación a partir de datos EEG [80], [81]. Otros estudios se basan en el análisis frecuencia-tiempo y usan EMD y sus variantes para desarrollar el análisis no lineal y no estacionario de señales, obteniendo resultados satisfactorios aplicados a la detección o clasificación de las convulsiones epilépticas [82], [83]. A partir de la investigación realizada, se observa que resultados de clasificación exitosos se obtienen mediante algoritmos de clasificación como Máquinas de Soporte Vectorial [84], redes neuronales artificiales [85] y Machine Learning [86], entre otros.

Los resultados obtenidos los autores en [87], fueron analizados a partir de un conjunto de 16 pacientes con epilepsia los cuales están bajo tratamiento en el Departamento de Neurología de la Facultad de Medicina de la Univesidad Izmir Katip Celebi, en Turquía. Para analizar las grabaciones EEG, los autores usan EMD y EEMD con varios clasificadores para identificar las IMF's que mejor representen la señal original. Posteriormente del proceso de selección de IMF, un conjunto de características fueron creadas usando las IMF1, IMF2 e IMF3. Adicionalmente, se usa DWT para comparar el comportamiento de la señal. Finalmente, los clasificadores SVM, KNN, Naive Bayes y regresión logística son usados para evaluar los resultados.

Los resultados de [87] se resume en cuatro tablas donde la primera de ellas resume el comportamiento de las características en el dominio del tiempo. A partir de ello las IMF1, IMF2 e IMF3, obtienen resultados a partir de los clasificadores usados para el estudio. En otra tabla generan las métricas de rendimiento para las características espectrales utilizadas en la clasificación para diferentes combinaciones de IMF. Una nueva tabla muestra los resultados de clasificación usando características no lineales mostrando resultados con

mas del 95 % de exactitud usando EMD y clasificadores como KNN y SVM. Finalmente se determina el efecto de la selección de las IMF's en el desempeño de la clasificación.

El principal objetivo según expresan los autores, es presentar un método híbrido de selección de IMF y explorar el efecto de las IMFs extraídas por EMD. Los autores investigan las ventajas de usar EEMD donde las versiones de las señales de ruido añadido son descompuestas para eliminar el problema de modo mixto de la EMD. En la literatura existen diversos artículos que estudian la detección y clasificación de convulsiones epilépticas y han sido enfocados en este campo usando EMD y sus enfoques derivados, los cuales son capaces de analizar las señales no lineales y no estacionarias como son las señales EEG [83], [88]. En la mayoría de los estudios mencionados hasta el momento, al igual que en [89] y [90], las primeras 5 IMFs o las primeras 4 IMFs fueron seleccionadas porque contienen información de alta frecuencia. Por ello, los autores proponen un enfoque híbrido de selección de IMF considerando energía, correlación, distancia espectral de potencia y medidas de significación estadística y para ello analizan las ventajas de la selección de IMF propuesta en los enfoques EMD y EEMD.

## 1.4. Objetivos

### ■ Objetivo General

Proponer un método automatizado de detección de convulsiones epilépticas utilizando redes neuronales profundas y descomposición empírica de modos.

### ■ Objetivos Específicos

1. Realizar la descomposición de las señales EEG empleando Descomposición Empírica de Modos (EMD ) con el fin de encontrar un conjunto de frecuencias que describan el comportamiento eléctrico de la patología.
2. Diseñar una estrategia de selección de variables a partir del análisis de tiempo multidimensional realizado con el EMD.
3. Clasificar de manera automática las señales EEG descompuestas mediante el

uso de técnicas de aprendizaje profundo.

El presente documento se estructura de la siguiente manera: en el Capítulo 2, se realiza una exhaustiva revisión de la literatura, abordando la descripción matemática de los métodos de descomposición de señales y las redes neuronales artificiales. En el Capítulo 3, se detalla la metodología implementada para alcanzar los objetivos específicos propuestos. Posteriormente, en el Capítulo 4, se presentan los resultados obtenidos a partir de la aplicación de dicha metodología. El Capítulo 5 se dedica a la discusión de los resultados, resaltando la importancia y relevancia de la investigación realizada. Finalmente, en el Capítulo 6 se formulan las conclusiones derivadas de este trabajo de grado, acompañadas de recomendaciones para futuras investigaciones.

## 2. Revisión de la Literatura

En esta sección se realizará una detallada descripción de los métodos empleados con frecuencia para realizar la extracción de características de las señales EEG. Se mostrará la descripción matemática de cada uno de estos y se analizará sus principales ventajas y desventajas.

### 2.1. Transformada de Fourier (TF)

La Transformada de Fourier es una de las herramientas más usadas en el análisis de señales y de series de tiempo. Esta estrategia se utiliza en diferentes campos de la ingeniería donde el análisis de sistemas dinámicos requiere un análisis tiempo-frecuencia, y en donde las series de Fourier, las cuales están basadas en una suma de señales sinusoidales, no son suficientes debido a la naturaleza de las señales bajo estudio [91]. Al representar funciones no periódicas se sustituyen las series de Fourier por las transformadas de Fourier, las cuales son de gran aplicación en diferentes campos de la ciencia y de la ingeniería como lo son: comunicaciones, procesamiento de señales, procesamiento de imágenes, bioingeniería, óptica, electrónica, mecánica [92].

En el campo de la medicina, la TF es usada para analizar diversos tipos de señales, por ejemplo: electroencefalográficas [93], magnetoencefalográficas [94], electromiográficas [95], [96] y electrocardiografía [97], [98], también se relaciona el análisis de Fourier con el análisis espectral del comportamiento global de los cromosomas, análisis de la variabilidad de la frecuencia cardíaca, procesamiento de imágenes por econogramas, resonancia magnética y tomografía axial computarizada [99].

La Transformada de Fourier tiene como finalidad encontrar una representación en el dominio de la frecuencia de una señal sobre la cual solo se tiene información en el dominio del tiempo. Se tratará a la TF como una herramienta básica en el análisis de señales no periódicas que tienen energía finita [100]. La TF permite analizar una señal periódica en el dominio del tiempo dado su contenido en frecuencia. Esto se debe a que los coeficientes de Fourier de la función transformada representan la contribución de cada función seno

según cada armónico [101]. Bajo ciertas condiciones, es posible, después de haber realizado el estudio en el dominio de la frecuencia, retornar al dominio del tiempo aplicando para ello la antitransformada de Fourier. Así, la TF requiere del desarrollo de una teoría matemática compleja que requiere de algunos conceptos básicos para su entendimiento.

Sea  $x(t)$  una señal no periódica definida en todo el intervalo real y  $x_T(t)$  ( $T > 0$ ) la señal  $2T$  periódica que se obtiene a partir de  $x(t)$  haciendo  $x_T(t) = x(t)$  para  $t \in [-T, T)$  con periodo  $2T$ . Al suponer que  $x(t)$  es suficientemente suave, entonces se tiene la identidad [102]:

$$x(t) = x_T(t) = \frac{1}{2T} \sum_{k=-\infty}^{\infty} \left[ \int_{-T}^T x(s) e^{(-\pi i/T)kt} ds \right] e^{(\pi i/T)kt} \quad (1)$$

Si  $T \rightarrow \infty$  en el segundo miembro de la desigualdad anterior, la igualdad límite será válida para todo  $t \in \mathbb{R}$  y su valor será igual al de la señal de partida  $x(t)$ .

Ahora se analiza si  $T \rightarrow \infty$  en el segundo miembro de la igualdad anterior. Tomando  $\Delta f = 1/(2T)$  y  $f_k = k\Delta f$ , se puede escribir (1) como [100]:

$$x(t) = \sum_{k=-\infty}^{\infty} \Delta f \left[ \int_{-T}^T x(s) e^{-2\pi i f_k s} ds \right] e^{2\pi i f_k t} \quad (2)$$

Ahora,  $|f_{k+1} - f_k| = \Delta f = 1/2T$  ( $k \in \mathbb{Z}$ ) y por lo tanto se pueden interpretar los puntos  $f_k$  como nodos equiespaciados de una partición de Riemann para la integral límite.

$$\int_{-\infty}^{\infty} \left( \int_{-\infty}^{\infty} x(s) e^{-2\pi i f s} ds \right) e^{2\pi i f t} df \quad (3)$$

Es decir, es posible afirmar que bajo ciertas condiciones restrictivas sobre la suavidad de la señal no periódica  $x(t)$  se satisface la identidad [100]:

$$x(t) = \int_{-\infty}^{\infty} \left( \int_{-\infty}^{\infty} x(s) e^{-2\pi i f s} ds \right) e^{2\pi i f t} df \quad (4)$$

La identidad (4) es conocida como el Teorema Integral de Fourier. Haciendo el siguiente cambio de variable  $\xi = 2\pi f$ , se puede reescribir la identidad anterior como:

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \left( \int_{-\infty}^{\infty} x(s) e^{-i\xi s} ds \right) e^{i\xi t} d\xi \quad (5)$$

La señal:

$$\mathcal{F}(x)(\xi) := \hat{x}(\xi) := \int_{-\infty}^{\infty} x(s) e^{-i\xi s} ds \quad (6)$$

tiene el nombre de **Transformada de Fourier** de la señal no periódica  $x(t) \in L^1(\mathbb{R})$ .

La señal:

$$\mathcal{F}^{-1}(y)(t) := \frac{1}{2\pi} \int_{-\infty}^{\infty} y(\xi) e^{i\xi t} d\xi \quad (7)$$

toma el nombre de **Transformada inversa de Fourier** de la señal no periódica  $y(\xi)$

## 2.2. Transformada Wavelet (TW)

La Transformada Wavelet es otra de las herramientas usadas en ingeniería, análisis numérico, probabilidad y estadística [103]. El término wavelet fue dado a conocer aproximadamente en los años de 1980 y fue visto como una síntesis de ideas de diferentes disciplinas que abarcan matemáticas, física e ingeniería y siendo ampliamente usado en la actualidad como una herramienta de procesamiento de señales [104], ya que se caracteriza como una rápida y eficiente forma de analizar señales transitorias de voltaje y corriente, así mismo es útil para caracterizar señales electroencefalográficas [105].

En 1982 Jean Morlet en colaboración con un grupo de ingenieros franceses presenta la idea de wavelet como una familia de funciones construidas usando traslaciones y dilataciones de una función única llamada wavelet madre para el análisis de señales no estacionarias, no periódicas, con ruido, intermitentes y transitorias, proporcionando una nueva herramienta matemática en el análisis de ondas sísmicas, primera aplicación realizada con la transformada [106].

La TW descompone una señal en bandas de frecuencia, las cuales son generadas por

medio de la wavelet madre y las operaciones de traslación en el dominio del tiempo [105]. También responde a la necesidad de una resolución frecuencia-tiempo óptima en todos los rangos de frecuencia. Para mejorar el tiempo de resolución para los transitorios de altas frecuencias y la buena resolución de frecuencia para los componentes de baja frecuencia, se define el concepto de wavelet madre como [105], [107]:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right), a, b \in \mathbb{R}, a \neq 0 \quad (8)$$

En este caso,  $a$  es llamado parámetro de escala el cual mide el grado de compresión o escala. Del mismo modo,  $b$  se conoce como el parámetro de traslación el cual determina el tiempo de ubicación de la wavelet [107].

Una wavelet es una función  $\psi(t) \in L^2(\mathbb{R})$  con media cero.

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (9)$$

La transformada wavelet discreta (DWT en inglés) es obtenida discretizando los valores de  $a$  y  $b$ . En su forma mas común, la DWT emplea un muestreo diádico con los parámetros  $a$  y  $b$  basados en potencias de  $2a = 2^j$  y  $b = k2^j$ , con  $j, k \in \mathbb{Z}$ . Sustituyendo los parámetros discretizados en la ecuación (8), se obtienen las wavelet diádicas:

$$\psi_{j,k}(t) = \frac{1}{\sqrt{2^j}} \psi\left(\frac{t}{\sqrt{2^j}} - k\right) \quad (10)$$

Además, la DWT de una señal  $s(t)$  puede ser escrita como:

$$d_{j,k} = \int_{-\infty}^{\infty} s(t) \psi_{j,k}^*(t) dt = \langle s(t), \psi_{j,k}(t) \rangle \quad (11)$$

donde  $d_{j,k}$  son conocidos como coeficientes wavelet en el nivel  $j$  y ubicación  $k$ .  $s(t)$  es la transformada wavelet continua de una señal  $s(t)$ .

### 2.3. Descomposición Empírica de Modos (EMD)

La Descomposición Empírica de Modos (Empirical Mode Decomposition, EMD) es un método adaptativo para el análisis de señales no lineales y no estacionarias y tiene como objetivo descomponer una señal no lineal y no estacionaria en una suma de funciones de modo intrínseco (IMF) o modos que satisfacen las siguientes condiciones [108], [109]:

1. En todo el conjunto de datos, el número de extremos y el número de cruces por cero debe ser igual o diferir como máximo en uno.
2. En cualquier punto, el valor medio de la envolvente definida por los máximos locales y la envolvente definida por los mínimos locales es cero. La segunda condición implica que una IMF es estacionaria lo que simplifica su análisis. Pero una IMF puede tener modulación de amplitud y frecuencia cambiante [110].

La EMD presenta algunos problemas como la presencia de oscilaciones de amplitud desigual en uno o mas modos, o de oscilaciones similares en diferentes modos, fenómeno conocido como mezcla de modos. El proceso de tamizado se puede resumir en el siguiente algoritmo. Descomponer un conjunto de datos  $x(t)$  en IMFs  $x_n(t)$  y un residuo  $r(t)$  tal que la señal pueda ser representada como:

$$x(t) = \sum x_n(t) + r(t) \quad (12)$$

La figura 1 exhibe la secuencia de pasos que comprenden la descomposición de señales mediante el método EMD, incluyendo la identificación de modos intrínsecos y otros procesos.

### 2.4. Transformada de Hilbert (TH)

La transformada de Hilbert es uno de los operadores mas importantes en el procesamiento y teoría de señales digitales y es fundamental para mantener las relaciones entre la parte real y la parte imaginaria o entre la amplitud y fase de la transformada de Fourier de una secuencia [111]. Las primeras aplicaciones de la transformada de Hilbert fueron propuestas

por Simon y Tomlinson los cuales proporcionaron una herramienta para un método de detección no lineal basada en la respuesta en frecuencia de la función de un sistema lineal es invariante bajo una transformada de Hilbert.

Dada una función  $u(t)$  su transformada de Hilbert  $H(u\{t\})$  es definida como [112]:

$$H\{u(t)\} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{u(s)}{t-s} ds \quad (13)$$

Su primer uso se remonta al año de 1905 en el trabajo de Hilbert sobre funciones analíticas. La importancia de la transformación se debe a la propiedad de extender funciones reales a funciones analíticas. Esta propiedad indudablemente induce a un gran número de aplicaciones, especialmente en la teoría y el procesamiento de señales [113].

## 2.5. Transformada de Hilbert Huang (HHT)

El desarrollo de la Transformada de Hilbert Huang (HHT) surge de la necesidad de describir las ondas no lineales distorsionadas junto con variaciones de esas señales que naturalmente ocurren en procesos no estacionarios [114]. La HHT combina la EMD y la TH anteriormente mencionadas; en este caso, la EMD descompone señales en monocomponentes llamadas funciones de modo intrínseco (IMFs) de las cuales es posible obtener amplitud  $a(t)$  y frecuencias instantáneas  $f_i(t)$  [115].

Lo anterior se manifiesta como objetivo de la HHT disponer de una herramienta para gestionar el paradigma tiempo-frecuencia-energía de los datos. La no linealidad y la no estacionariedad pueden tratarse mejor que utilizando los paradigmas de frecuencia y amplitud constantes [105].

El espectro de Hilbert (HS) es una representación en 3D de la amplitud instantánea y frecuencia instantánea como una función del tiempo para cada IMF. Se define el HS como [105]:

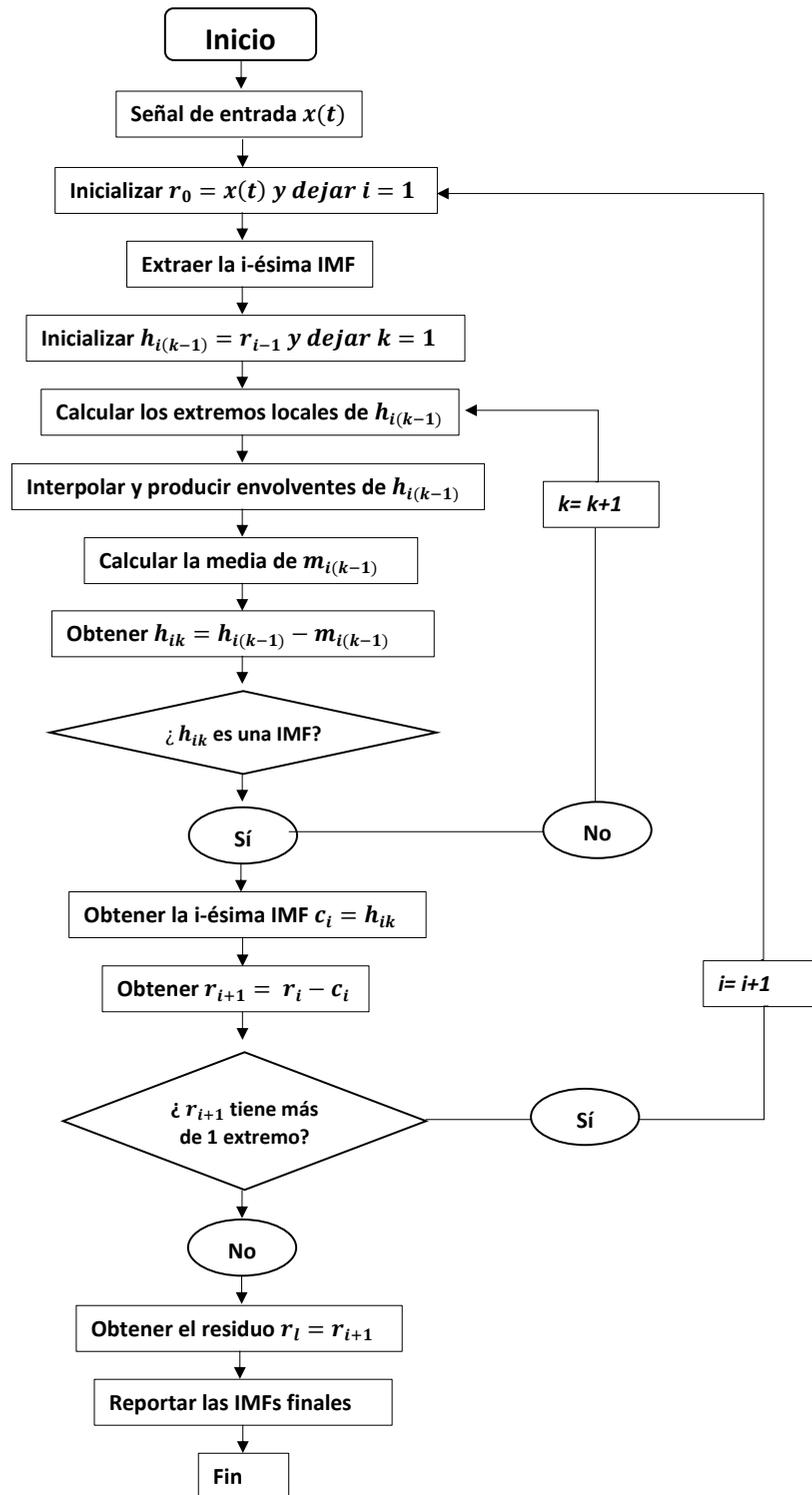


Figura 1: Diagrama de flujo de EMD.

$$H_i(f, t) \triangleq \begin{cases} a_i(t) & \text{para } f = f_i(t) \\ 0 & \text{otro caso} \end{cases} \quad (14)$$

Para una señal multicomponente general, el espectro de Hilbert está definido como la suma de los espectros de Hilbert de todos las IMFs, como se indica en:

$$H(f, t) \triangleq \sum_{i=1}^N H_i(f, t) \quad (15)$$

donde N es el número total de IMFs.

## 2.6. Machine Learning (ML)

El Machine Learning es una disciplina del campo de la Inteligencia Artificial que permite a los ordenadores, a través de algoritmos, aprender por sí solos permitiendo realizar funciones de forma autónoma. El objetivo de esta técnica relacionada con el ámbito de la inteligencia artificial, es identificar patrones de repeticiones estadísticas y extraer predicciones estadísticas basados en ellos, siendo la minería de datos la materia prima para el Machine Learning, permitiendo la identificación de patrones para la predicción estadística [116]. Los sistemas basados en ML están siendo aplicados en diversas aplicaciones de la vida diaria como la identificación de objetos en imágenes, transcribir voz en texto, relacionar noticias, publicaciones o productos con intereses de los usuarios [37]. Los principales algoritmos basados en ML son: el aprendizaje supervisado la cual es una técnica donde se enseña a una máquina mediante un algoritmo que contiene una colección de base de datos a realizar una tarea específica y el aprendizaje no supervisado los cuales son algoritmos que no cuentan con un conocimiento previo y permite a una máquina aprender por sí sola [117]. Algunas de las aplicaciones del Machine Learning son [118]:

### 1. Aplicaciones de Visión por Computador

Los sistemas de análisis de video en tiempo real manejan un rango amplio de aplicaciones con gran impacto en la sociedad como por ejemplo autonomía en vehículos, realidad aumentada, vigilancia y planificación de tráfico [119]. Estas aplicaciones usan algoritmos de ML unido a redes neuronales o máquinas de soporte vectorial que facilitan el desarrollo de la aplicación, además de mejorar los resultados obtenidos [120]. Otras aplicaciones importantes son las técnicas de reconocimiento de imágenes y visión por computador donde se extrae información relevante de una imagen con el fin de identificar un objeto particular en esta, siendo la base para muchas de las aplicaciones de dispositivos y usuarios móviles [121]. Estas aplicaciones basadas en el reconocimiento se basan en técnicas complejas computacionales como el Machine Learning e Inteligencia Artificial que requieren de un gran conjunto de datos y suficientes recursos informáticos para brindar resultados precisos y oportunos.

## 2. Reconocimiento Automático de Voz

Diferentes investigadores están interesados sobre el desarrollo de sistemas de reconocimiento de voz. El reconocimiento de voz de vocabulario limitado, también conocido como detección de palabras clave, es un método para lograr el reconocimiento de voz sin conexión y está compuesto de dos componentes [122]:

- a. Extractor de características para identificar señales necesarias de la voz humana.
- b. Red neuronal basada en clasificadores los cuales toman las características de la voz como entrada y genera un conjunto de probabilidad para cada palabra clave como salida.

## 3. Detección

Se han usado diferentes aplicaciones en detección como son el diagnóstico médico, seguridad, detección de objetos en imágenes [123]. Así, el **ML** juega un papel importante en la detección, donde diferentes investigaciones se enfocan en realizar y explicar la arquitectura presente en este tipo de aplicaciones donde parámetros

como: rendimiento, precisión, sensibilidad y especificidad califican un adecuado proceso de aprendizaje [124].

#### 4. **Privacidad de Uso**

En la actualidad debido al auge que ha tenido la tecnología y el uso generalizado de dispositivos basados en el Internet de las Cosas (IoT) ha impulsado la producción de datos personales. Sin embargo, las protecciones de seguridad inadecuadas en estos dispositivos han aumentado simultáneamente el potencial de uso indebido de los datos del usuario [118]. Debido a esto, se encuentran investigaciones relacionadas con la protección de la privacidad de los usuarios diseñando arquitecturas que funcionan basados en bases de datos que son procesadas por medio de ML, redes neuronales e IA [125].

### 2.7. **Deep Learning (DL)**

La Inteligencia Artificial (AI) es una disciplina que ha existido hace décadas agrupando un campo amplio de aplicación. La AI puede ser visto como un conjunto que abarca al Machine Learning (ML) y al Deep Learning (DL). El ML es un subconjunto de IA, mientras que el DL, a su vez, un subconjunto del ML. El Deep Learning es un subconjunto de Machine Learning que permite a los modelos computacionales, los cuales están compuestos de múltiples capas de procesamiento, aprender representaciones de datos con diferentes niveles de abstracción y donde las redes neuronales, algoritmos inspirados en cómo funciona el cerebro humano, aprenden de grandes cantidades de datos [37], [126].

Al ser subconjunto del ML, existen variadas aplicaciones que se han venido desarrollando a lo largo de los últimos años como son la identificación de objetos en imágenes, selección de resultados relevantes en una búsqueda, transcripción de voz a texto; toda esta clase de aplicaciones hacen uso de técnicas conocidas como Deep Learning [127].

Esta técnica está realizando significantes avances en solución de problemas que hasta hace algún tiempo habían sido considerados como imposibles para una comunidad que trabajaba con inteligencia artificial [128]. Ha resultado ser una excelente herramienta pa-

ra trabajar con datos de alta complejidad y dimensión y por esto es útil a los diferentes dominios de la ciencia, negocios y gobierno. Para algunos expertos en el tema, lo mas sorprendente del Deep Learning es el crecimiento de resultados extremadamente prometedores para tareas relacionadas con la comprensión del lenguaje natural, en especial la clasificación de temas, el análisis de sentimientos, la respuesta a preguntas y la traducción de idiomas [129].

El aprendizaje supervisado es la metodología mas importante en el área del Machine Learning. Este tipo de metodología implica el aprendizaje de una asignación entre un conjunto de variables de entrada  $\mathbf{X}$  y una variable de salida  $\mathbf{Y}$  y la aplicación de esta asignación para predecir los resultados de los datos no vistos [130].

## **2.8. Redes Neuronales Artificiales (ANNs)**

En los últimos años, las redes neuronales artificiales se han convertido en una herramienta indispensable para investigaciones tanto a nivel académico como laboral donde es utilizado en modelos de clasificación, patrones de reconocimiento y predicción y otras disciplinas [131]. Una red neuronal artificial es una estructura de unidades interconectadas de una numerosa cantidad de neuronas. Cada neurona es capaz de recibir señales de entrada para procesarlas y enviarlas como una señal de salida [132]. En [133] expresan que una ANN puede ser comparada como una máquina que funciona de la misma manera que lo hace el cerebro humano, pues está constituida por la interconexión de múltiples neuronas que reciben y envían información mediante un tipo de señal, trabajando en conjunto para resolver problemas específicos.

Hoy en día, las ANN son frecuentemente usadas por sus excelentes propiedades de auto aprendizaje, adaptabilidad y precisión de acuerdo a los diferentes problemas que se quieran solucionar. Son capaces de proporcionar eficientes resultados en campos como la ciencia, medicina, finanzas, ingeniería y esos retos que no pueden ser solucionados mediante procedimientos computacionales tradicionales o matemáticas convencionales [134].

Las ANN están compuestas de capas. La mas común está compuesta por tres de ellas: una

capa de entrada, una capa oculta y una capa de salida siendo independiente una de la otra lo que permite tener un número arbitrario de nodos para cada una de ellas y constituyendo la estructura neuronal del sistema. El concepto de neuronas, función de transferencia y conexiones son los principales elementos que conforman las ANNs. De forma general, las ANNs se pueden dividir en las siguientes cuatro categorías [135]:

1. **Predicción:** usa los valores de entrada para predecir los valores de salida. El modelo de *backpropagation* (propagación hacia atrás), es el más usado para predicciones en ingeniería siendo un mecanismo poderoso para establecer funciones de transferencia no lineales entre un número de valores continuos de entrada [136].
2. **Clasificación:** usa los valores de entrada para determinar la clasificación y es generalmente usado por patrones de reconocimiento [137].
3. **Asociación de datos:** usa simulación para la clasificación, al mismo tiempo que reconoce datos que contienen errores [124].
4. **Filtrado de datos:** analiza los datos de entrada y los suaviza para la salida [138].

Una ANN está conformada por tres acciones principales las cuales son:

1. Su patrón de conexión entre neuronas.
2. Su método de determinar los pesos sobre las conexiones.
3. Su función de activación [139].

### Elementos básicos de una ANN

Como se enunció anteriormente, una red neuronal está constituida por neuronas interconectadas y arregladas en capas. La figura (2) muestra un esquema de su configuración.

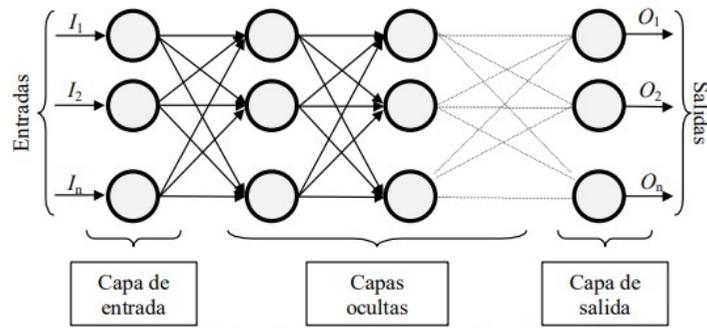


Figura 2: Diagrama de una red neuronal artificial básica [132]

A partir de la configuración mostrada, se observa que los datos con los cuales se realizará un estudio ingresan por la capa de entrada, realizan las operaciones necesarias con el fin de evaluar o dar una respuesta a un determinado problema que se quiera resolver mediante las capas ocultas y finalmente se obtiene un resultado en la capa de salida [140]. Las principales funciones son:

- Función de entrada:** en esta parte existen varios valores de entrada donde la neurona trata a todos estos valores como si fueran uno solo; para ello se usa la *función de entrada*, la cual se analiza a partir del *vector de entrada*. Esta función puede notarse como:

$$input_i = (in_{i1} \cdot w_{i1}) * (in_{i2} \cdot w_{in}) * (in_{in} \cdot w_{in}) \text{ donde :}$$

$n$ : número de entradas a la neurona  $N_i$ .

$w$ : peso asignado a la neurona.

Ahora, los valores de entrada se multiplican por los pesos asignados a la neurona. Se debe tener en cuenta que el valor de los pesos se pueden modificar en mayor o menor medida dependiendo del valor de la entrada.

- Función de activación:** las neuronas pueden estar activas o inactivas, es decir, poseen un estado de activación dependiendo del proceso que se esté realizando. Las neuronas artificiales pueden tener diferentes estados de activación o también pueden

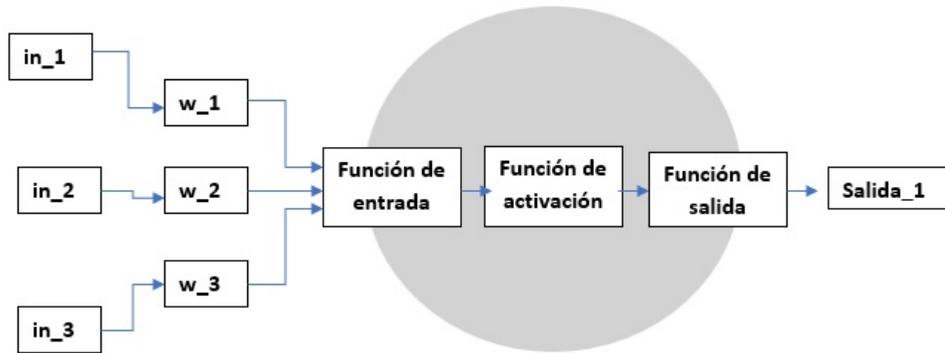


Figura 3: Neurona con 3 entradas y 1 salida  
[133]

tomar cualquier valor dentro de un rango determinado. La *función de activación* calcula el estado de actividad de una neurona transformando la entrada global en un valor de activación, en un rango que generalmente va de 0 a 1 donde la neurona está activa o -1 a 1 donde la neurona está inactiva [140]. Algunas de las funciones de activación más usadas son las siguientes:

1. **Función Lineal:** permite que los valores de entrada sean iguales a los valores de salida, es decir, si se tiene una red neuronal de varias capas y se aplica esta función se tendrá una regresión lineal. Su comportamiento se muestra en la figura 4.

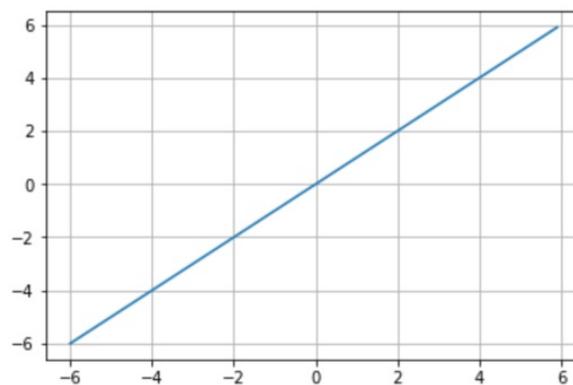


Figura 4: Función de activación lineal  
[140]

2. **Función Escalón Unitario:** es una función discontinua definida así:

$$u(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases} \quad (16)$$

Es frecuentemente usada en ingeniería para representar señales y su comportamiento se observa en la figura 5. Como función de activación claramente expresa un estado de activación o desactivación de la neurona dependiendo el número que tenga.

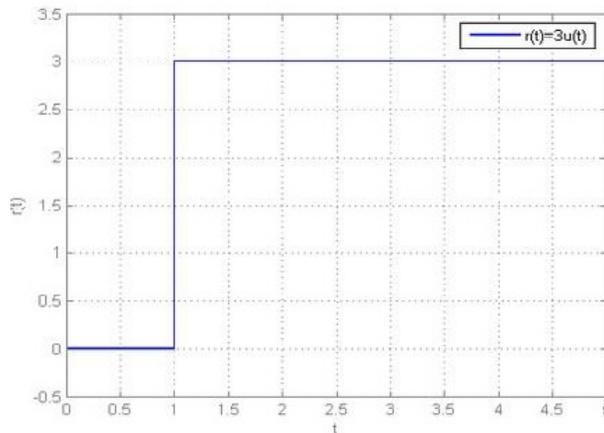


Figura 5: Función escalón unitario  
[140]

3. **Función Sigmoidal:** toma cualquier rango de valores en la entrada y los mapea al rango  $[0, 1]$  en la salida. El comportamiento de esta función se muestra en la figura 6:

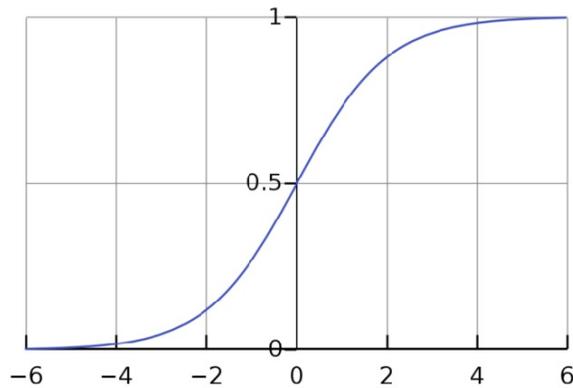


Figura 6: Función sigmoide  
[140]

Esta función de activación tiene uso limitado debido al problema de saturación, ya que la función se satura al valor de 1 cuando la entrada es muy alta y a 0 cuando es muy baja [141].

4. **Función Tangente Hiperbólica:** con un comportamiento similar a la función sigmoide, la diferencia radica en los valores de salida que se ubican en el rango  $[-1, 1]$  como se muestra en la figura 7.

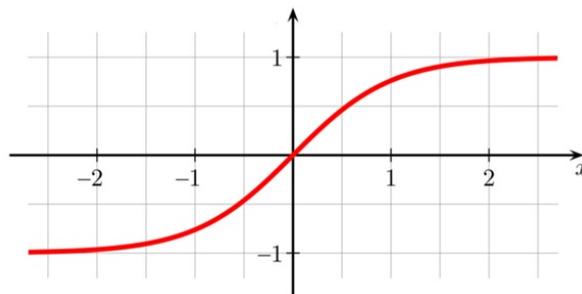


Figura 7: Función tangente hiperbólica  
[141]

5. **Función ReLU:** es la función de activación más usada debido a que permite el rápido aprendizaje en las redes neuronales. Su nombre viene de las siglas en inglés *Rectified Linear Unit* o Unidad Lineal Rectificada. Su comportamiento es el que se muestra en la figura 8 siguiente:

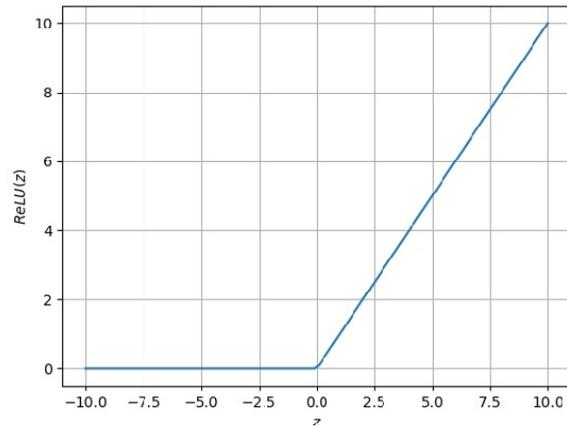


Figura 8: Función de activación ReLu  
[141]

Esta función genera una salida igual a 0 cuando la entrada sea negativa y una salida igual a la entrada cuando esta sea positiva. Las principales ventajas son:

- No tiene saturación, lo que permite que el algoritmo de gradiente descendente converja más rápidamente, facilitando el entrenamiento.
- Es más fácil de implementar computacionalmente en comparación con otras funciones que requieren cálculos matemáticos y funciones más complejas [141]

- **Función de salida:** proporciona el valor de salida de la neurona en base al estado de activación de esta.

### **3. Metodología de la Investigación**

En este capítulo, se detalla el procedimiento seguido para obtener y evaluar los resultados en el contexto del caso de estudio abordado. Se inicia con la caracterización de las señales extraídas de una base de datos pública, evaluando su comportamiento para determinar de manera automatizada la presencia o ausencia de convulsiones en los exámenes electroencefalográficos de los pacientes.

A continuación, se presentan los resultados derivados de la implementación de la metodología propuesta, que abarca la estrategia para clasificar y descomponer señales EEG. Esta metodología incorpora tanto redes neuronales como algoritmos de descomposición, proporcionando un enfoque integral para el análisis de las señales.

#### **3.1. Elección de la Base de Datos**

Con el fin de elegir la base de datos apropiada para realizar la descomposición y clasificación de señales epilépticas, es necesario realizar un mapeo sistemático donde se muestren resultados de investigadores que utilicen y propongan diferentes bases de datos que contengan información significativa sobre un caso de estudio en particular. Para el presente trabajo de investigación, se desea que la base de datos contenga información relacionada con los exámenes o tests realizados a pacientes que sufren convulsiones epilépticas. Se desea también que la base de datos se encuentre de forma pública para aprovechar al máximo toda la información almacenada.

Para iniciar el procesamiento, descomposición y clasificación de señales EEG, se elige la base de datos con la cual se realizará la investigación. Para el presente caso de estudio, donde se desea realizar la clasificación de convulsiones epilépticas de manera automática, se usó la base de datos de Physionet la cual consiste en señales obtenidas del cuero cabelludo de 23 pacientes pediátricos con convulsiones intratables del Boston Children's Hospital, la cual se encuentra de forma pública en la página web de Physionet [142]. En la figura (9) se observa una vista general de la página web mencionada.

## CHB-MIT SCALP EEG DATABASE

The new PhysioNet website is available at: <https://physionet.org>. We welcome your [feedback](#).

This database is described in

Ali Shoeb, *Application of Machine Learning to Epileptic Seizure Onset Detection and Treatment*. PhD Thesis, Massachusetts Institute of Technology, September 2009.

Please cite this publication when referencing this material, and also include the standard citation for PhysioNet:

Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng C-K, Stanley HE. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* 101(23):e215-e220 [Circulation Electronic Pages: <http://circ.ahajournals.org/cgi/content/full/101/23/e215>]; 2000 (June 13).

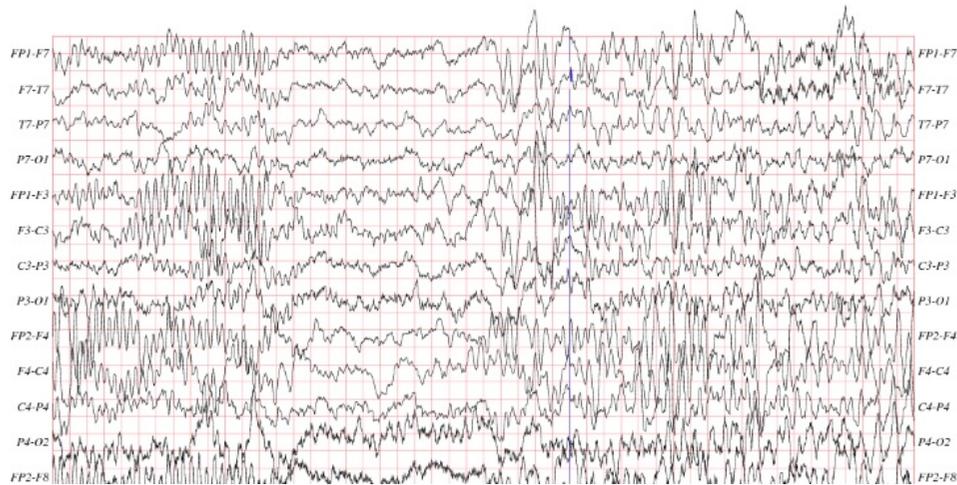
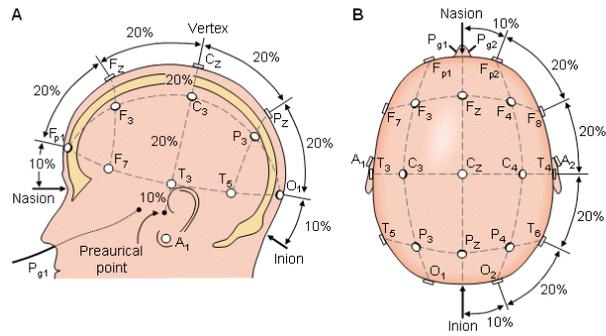
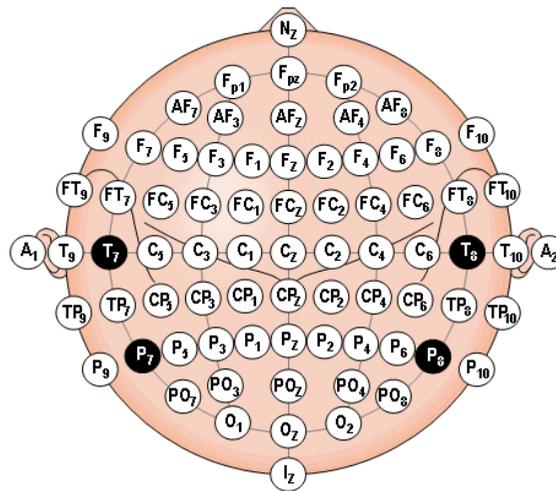


Figura 9: Página web de Physionet  
[142]

Las grabaciones de las señales EEG fueron adquiridas usando electrodos ubicados sobre el cuero cabelludo de los pacientes utilizando diferentes configuraciones [11]. Los pacientes fueron tanto hombres como mujeres en edades entre los 3 y 22 años y 1.5 a 19 años, respectivamente. Todas las señales fueron adquiridas a 256 muestras por segundo con una resolución de 16 bits. La mayoría de los archivos contienen 23 señales EEG, aunque en algunos casos los autores optaron por incluir 24 y se usó la nomenclatura del método “**International 10-20 System**”, método reconocido internacionalmente para definir la posición de los electrodos en el cuero cabelludo. La figura 10 muestra la ubicación de los electrodos de acuerdo al método mencionado.



(a) International 10-20 system visto desde (A) lado izquierdo y (B) parte superior de la cabeza



(b) Ubicación de electrodos visto desde la parte superior de la cabeza

Figura 10: Ubicación de electrodos de acuerdo al International 10-20 System [143]

En la tabla 2 se muestra los canales que se están midiendo de acuerdo a la configuración expuesta.

Cada una de las grabaciones fueron anotadas por expertos en el área indicando los tiempos de inicio y finalización de las convulsiones epilépticas [144]. Para cada caso, se han analizado un total de 941.6 horas de actividad inter-ictal y 3 horas de actividad ictal de las 181 convulsiones descritas en la base de datos.

Tabla 2: Ubicación de los electrodos según el método International 10-20 System

Canal	Lectura
1	FP1-F7
2	F7-T7
3	T7-P7
4	P7-O1
5	FP1-F3
6	F3-C3
7	C3-P3
8	P3-O1
9	FP2-F4
10	F4-C4
11	C4-P4
12	P4-O2
13	FP2-F8
14	F8-T8
15	T8-P8
16	P8-O2
17	FZ-CZ
18	CZ-PZ
19	P7-T7
20	T7-FT9
21	FT9-FT10
22	FT10-T8
23	T8-P8

### 3.2. Pre-procesamiento de la Base de Datos

Posterior a la elección de la base de datos, se realiza un pre-procesamiento donde se define la estructura para responder a los requerimientos de la investigación. Se realiza la lectura de las señales derivadas y se analiza cual es el software mediante el cual puede ser leído y procesado el conjunto de señales. En esta etapa se remueven una serie de datos que no son significativos para el caso de estudio y que pueden alterar negativamente los resultados. Es necesario interpretar adecuadamente los resultados que se muestran en la base de datos, como también familiarizarse con el software de programación.

Para iniciar el pre-procesamiento de la base de datos con Physionet, se realiza una familiarización de esta, estableciendo los parámetros con los cuales se cuenta y que facilita la

lectura y el procesamiento de ellos. Algunas características con las que cuenta la base de datos son las siguientes:

- El archivo donde se encuentra la base de datos es un archivo de Matlab con extensión *.mat* llamado *EEG\_Classification\_Final.mat*. Dentro de este archivo se encuentran dos ficheros, el primero de ellos llamado **NS\_EEG\_F**, que corresponde a pacientes que no tienen convulsiones epilépticas y el segundo, **S\_EEG\_F** corresponde a pacientes que sí tienen convulsiones epilépticas.

En el enlace: [about\\_master\\_degree](#) y especialmente en el archivo `lectura_database.m` ubicado en el repositorio de GitHub se muestra el código de programación en MATLAB desde el cual se lee la base de datos en su estado original.

- El total de pacientes con los cuales se va a realizar la investigación es de 595. De los casos analizados, 120 pertenecen a pacientes que sufren convulsiones epilépticas y el restante, es decir 475 pacientes, hacen parte de personas que no tienen convulsiones. En la mayoría de los casos, el número de canales que se muestran en el test EEG es de 23 aunque en algunos casos varía a 24. Esta variabilidad con el número de canales, que llega a ser de 24 en algunos pacientes, no parece tener una razón específica, según la información proporcionada en la página web de Physionet. Esto depende de las decisiones tomadas por los autores de la base de datos al seleccionar el número de canales para ciertos pacientes. Así mismo, el número de muestras que se toman por canal es de 3600, siendo este valor el que se observa con mayor frecuencia. En otros casos se muestran canales con 959, 7200 y 14427 muestras analizadas.
- Como se mencionó anteriormente, los archivos pertenecientes a la base de datos, son archivos con una extensión *.mat*, archivos que pueden ser leídos mediante el software de simulación *Matlab*. Por cuestiones de implementación de código en posteriores etapas, se realiza la conversión de todos los archivos pertenecientes a la base de datos a un nuevo formato para una adecuada lectura de ellos. Este formato que se va a usar en adelante será un formato con extensión *.txt* el cual permite leer estos archivos en diferentes softwares de programación. En el archivo **files.txt**

del enlace [github.com/files\\_with\\_txt](https://github.com/files_with_txt) se muestran los archivos de la base de datos convertidos a formato txt.

### **3.3. Clasificación de convulsiones epilépticas mediante una red neuronal artificial**

Esta fase de la investigación tiene como objetivo llevar a cabo la primera aproximación para la clasificación de señales epilépticas a partir de la base de datos descrita en la sección anterior. Esta clasificación permite determinar a partir de un conjunto de datos suministrados, si una señal o un conjunto de señales adquiridas de un paciente, sea clasificada como una señal convulsiva o no. Para iniciar con el proceso de clasificación, es necesario realizar un estado del arte donde se muestre los avances que han realizado diferentes investigadores acerca la metodología y los software que implementan en diferentes casos de estudio.

Después de interpretar y leer la base de datos del caso de estudio, se realiza un primer acercamiento para llevar a cabo la clasificación de señales epilépticas mediante un nuevo software de programación. Para iniciar con el proceso de clasificación de señales se utiliza *Python*, lenguaje de programación interpretado, utilizado en gran variedad de aplicaciones en la actualidad y que permite desarrollar de manera sencilla y eficiente programas computacionales aplicado a un caso de estudio. Adicional a *Python*, se utiliza *PyCharm*, entorno de desarrollo integrado (IDE) que permite desarrollar de manera eficiente código de software y facilita al programador en el proceso.

Este lenguaje de programación unido al IDE, permiten realizar la clasificación de señales a través de un método de IA conocido como redes neuronales, modelo simplificado que simula el modo de operación de cómo el cerebro humano procesa la información. Este proceso funciona acoplado entre sí un numero elevado de unidades de procesamiento interconectadas y generalmente es comparado con el trabajo que realizan las neuronas en el cerebro humano, permitiendo realizar tareas con diferentes grados de dificultad [145].

Para realizar la clasificación de señales es necesario remitirse al capítulo II donde se

menciona la estructura de una red neuronal, modelo computacional utilizado actualmente en diversos estudios científicos que permite dar solución a problemas en sistemas complejos mediante algoritmos de programación, donde se procesan gran cantidad de datos con el objetivo de etiquetarlos o procesarlos. Con el uso de las redes neuronales para clasificar señales, es necesario establecer una metodología que permita establecer de forma ordenada una serie de etapas necesarias para lograr su implementación.

Teniendo en cuenta lo expuesto anteriormente, se presenta el modelo de una red neuronal recurrente (**RNN**), la cual es un tipo de red artificial que utiliza datos secuenciales o datos de series de tiempo que son utilizados para aprender a predecir y con la cual se va a realizar la clasificación de señales. Para implementarla, se empieza introduciendo las etapas que posee. De forma general, una red neuronal artificial de cualquier tipo está compuesta por cinco etapas:

1. **Importación de librerías:** esta etapa desarrolla un papel fundamental al proporcionar herramientas y recursos esenciales para la construcción, entrenamiento y evaluación de modelos de aprendizaje profundo. Es así como la elección y utilización de librerías especializadas, como por ejemplo Tensorflow y PyTorch justifican su presencia debido a la robustez que tienen en el ámbito de la inteligencia artificial. La incorporación de librerías da acceso a diversos conjuntos de funciones que simplifican la implementación de complejas arquitecturas de redes neuronales. Un ejemplo de ello es la librería Tensorflow, la cual ofrece una estructura versátil para la creación de modelos, permitiendo la definición de capas, funciones de pérdida y optimizadores de manera intuitiva.

La incorporación de NumPy y Matplotlib también se revela crucial, ya que NumPy facilita la manipulación eficiente de datos en forma de matrices, esenciales para la alimentación de modelos de redes neuronales. Por otro lado, Matplotlib permite la visualización efectiva de resultados, análisis de rendimiento y comprensión más profunda de los procesos de entrenamiento.

Adicionalmente, es necesario importar modelos a la red neuronal ya que su im-

portancia radica en la capacidad que tiene para representar y aprender patrones complejos a partir de datos con el objetivo de resolver problemas complejos, generalizar aprendizajes, automatizar tareas y adaptarse a diferentes contextos, lo que contribuye significativamente al progreso en la investigación y aplicación de la inteligencia artificial. En la tabla 3, se muestran las librerías usadas al implementar la red neuronal, de igual manera, en la tabla 4 se muestran los modelos importados.

Tabla 3: Librerías usadas en el software de clasificación de señales

	<b>Librerías</b>
<b>1</b>	Numpy
<b>2</b>	Pandas
<b>3</b>	csv
<b>4</b>	Tensorflow
<b>5</b>	Matplotlib
<b>6</b>	Matplotlib.pyplot

Tabla 4: Modelos implementados en la red neuronal

	<b>Modelo</b>
<b>1</b>	array
<b>2</b>	axes 3D
<b>3</b>	imdb
<b>4</b>	Sequential
<b>5</b>	Dense
<b>6</b>	LSTM
<b>7</b>	GRU
<b>8</b>	SimpleRNN
<b>9</b>	Dropout
<b>10</b>	optimizers
<b>12</b>	Conv2D
<b>13</b>	Embedding
<b>14</b>	sequence
<b>15</b>	classification_report, confusion_matrix

En las siguientes líneas de código, el cual fue implementado en el **IDE**, se muestran las librerías y modelos asignados al código de clasificación de señales.

1

```

2 import numpy as np
3 import pandas as pd
4 from numpy import array
5 import csv
6 import tensorflow
7 import matplotlib as mpl
8 from mpl_toolkits.mplot3d import Axes3D
9 import matplotlib.pyplot as plt
10 from keras.datasets import imdb
11 from keras.models import Sequential
12 from keras.layers import Dense
13 from keras.layers import LSTM
14 from keras.layers import GRU
15 from keras.layers import SimpleRNN
16 from keras.layers import Dropout
17 from keras import optimizers
18 from tensorflow.keras import optimizers #new line
19 from keras.layers import Conv2D,MaxPool2D,GlobalAveragePooling2D,
    AveragePooling2D
20 #from tensorflow.keras import GlobalAveragePooling2D
21 from keras.layers.embeddings import Embedding
22 from keras.preprocessing import sequence
23 from sklearn.metrics import classification_report,confusion_matrix

```

2. **Lectura de datos:** Después de importar las librerías esenciales, se realiza la lectura de datos, un paso fundamental en la implementación de una red neuronal. En el contexto de este proceso, los datos se dividen habitualmente en dos conjuntos distintos: el conjunto de entrenamiento y el conjunto de validación. Estos conjuntos desempeñan roles cruciales en el entrenamiento de la red y en la evaluación de su capacidad para reconocer patrones de clasificación.

El conjunto de entrenamiento cumple la función esencial de nutrir y enseñar a la red neuronal, proporcionándole ejemplos variados que le permiten aprender y ajustar sus parámetros para mejorar su capacidad predictiva. Por otro lado, el conjunto

de validación se utiliza para evaluar la eficacia y la generalización del modelo, al validar los resultados que la red ha aprendido durante el proceso de entrenamiento. Este enfoque de partición de datos es fundamental para lograr un equilibrio entre el aprendizaje efectivo de la red y su capacidad para generalizar a datos no vistos.

Para realizar la clasificación de señales epilépticas, el conjunto de datos se dividirán en dos: entrenamiento y validación. La base de datos se encuentra dividida de la siguiente forma:

- Conjunto de datos con convulsiones epilépticas.
- Conjunto de datos sin convulsiones epilépticas.

Para los grupos previamente mencionados, se lleva a cabo una subdivisión adicional, considerando los requisitos fundamentales para el funcionamiento efectivo de la red neuronal. Esta subdivisión se realiza en dos conjuntos esenciales: en primer lugar, el conjunto de entrenamiento, compuesto por el 70% del total de muestras, y en segundo lugar, el conjunto de validación, que comprende el restante 30%. La formación del marco de datos, que constituirá la base operativa, se completa al integrar el conjunto total de datos. La Tabla 5 presenta de manera detallada la distribución de datos, destacando el número de muestras asignadas a cada conjunto. Este enfoque estratégico garantiza una partición representativa y equilibrada de los datos, proporcionando así un sustento robusto para el entrenamiento y la evaluación del modelo de la red neuronal.

Tabla 5: Configuración del conjunto de entrenamiento y validación

Tipo de convulsión	Conjunto de entrenamiento	Conjunto de validación	Total
Epiléptica	84	36	120
No epiléptica	334	141	475

En la siguientes líneas de código se muestra la lectura de datos que se realiza en el **IDE** de **Python** con el objetivo de leer y organizar los conjuntos de entrenamiento y de validación. En el archivo RNN.py del enlace RNN ubicado en el repositorio

de GitHub se encuentra alojado el código implementado para realizar la primer iteración al modelo de redes neuronales.

```
1     print('El 70% de los pacientes que NO tienen convulsiones es: '
2         )
3     for i in range(1,476):
4         if i<Training_number_1:
5             with open('K%i.txt' %i, mode='r') as f:
6                 reader = csv.reader(f, delimiter='\t')
7                 data_as_list = list(reader)
8                 list_as_array.append(data_as_list)
9                 print(np.shape(data_as_list))
10        else:
11            with open('K%i.txt' %i, mode='r') as f: #csv_file:
12                reader = csv.reader(f, delimiter='\t')
13                data_as_list = list(reader)
14                #list_as_array2.append(reader)
15                list_as_array2.append(data_as_list)
16                print(np.shape(data_as_list))
17    print('El 70% de los pacientes que SI tienen convulsiones es: ')
18    for i in range(1,120):
19        if i<Training_number_2:
20            with open('P%i.txt' %i, mode='r') as f: #csv_file:
21                reader = csv.reader(f, delimiter='\t')
22                data_as_list = list(reader)
23                list_as_array.append(data_as_list)
24                print(np.shape(data_as_list))
```

En la figura 11 se muestra que el código implementado permite leer satisfactoriamente los vectores de entrenamiento y validación con el 70% y 30% de los datos, respectivamente, también se observa las filas y columnas que tienen cada una de las señales.

```
Run: RNN_jun_02
C:\Users\LENOVO\AppData\Local\Programs\Python\Python310\python.exe "C:/Users/LENOVO/Desktop/FILES IIT/CLEANEST FILES/RNN_jun_02.py"
2023-02-13 15:04:53.182947: W tensorflow/stream_executor/platform/default/dso_loader.cc:64] Could not load dynamic library 'cudart64_110.dll'; dlerror: cuda
2023-02-13 15:04:53.183772: I tensorflow/stream_executor/cuda/cudart_stub.cc:29] Ignore above cudart dlerror if you do not have a GPU set up on your machine
Implementación de Red Neuronal Recurrente

El 70% de los pacientes que NO tienen convulsiones es:
El 70% de los pacientes que SI tienen convulsiones es:
Finalización de ingreso de los datos...
-----
xtrain es:
(418, 14427, 24)
(176, 14427, 24)
ytrain es: (418, 2)

Process finished with exit code 0
```

Figura 11: Dimensiones de vectores de entrenamiento y validación

El resultado de la figura 11 se puede interpretar de la siguiente manera:

El conjunto de entrenamiento está compuesto por 418 señales, organizada en una estructura de 14427 filas y 24 columnas.

En cuanto al conjunto de validación, posee 176 señales, dispuestas en una estructura similar de 14427 filas y 24 columnas.

3. **Configuración de la red neuronal:** luego de realizar la lectura de la base de datos y de importar las librerías esenciales al código de programación, se da inicio a la configuración de la red neuronal. Este proceso se lleva a cabo en tres subetapas fundamentales:

- Estructura de clasificación del conjunto de entrenamiento.
- Estructura de clasificación del conjunto de validación.
- Configuración de parámetros de la red neuronal.

Para realizar la primer sub-etapa, se crea una matriz con las siguientes características:

- El numero de filas que tiene la matriz corresponde con el numero de datos de pacientes que hagan parte del conjunto de entrenamiento.
- El numero de columnas corresponderá con el número de respuestas que tendrá el proceso de clasificación.

- La matriz contiene solamente el valor de 1 o 0 en cada una de sus posiciones, que puede definirse, de acuerdo al proceso de clasificación que se esté estudiando, el valor de 1 como una señal positiva y el 0 como una señal negativa.
- Dependiendo de la organización de los datos de entrenamiento, la matriz tendrá en su primer posición un valor de 1 o de 0, o viceversa.

Para realizar la estructura de clasificación del conjunto de entrenamiento, se crea la matriz con las siguientes características:

- El número de filas que tiene la matriz será de 418, que corresponde al 70 % de muestras del conjunto de entrenamiento.
- El número de columnas de la matriz será de 2.
- La matriz tendrá dos valores: 1 y 0 los cuales representan una señal con convulsiones y sin convulsiones, respectivamente.
- De acuerdo a la organización de las señales con convulsiones y sin ellas,

Para la siguiente sub-etapa, se realiza un procedimiento similar al anterior, creando la estructura de clasificación del conjunto de validación con las siguientes características:

- El número de filas que tiene la matriz de validación será de 176, que corresponde al 30 % de muestras del conjunto de validación.
- El número de columnas de la matriz de validación será de 2.
- La matriz tendrá dos valores: 1 y 0 que representan una señal con convulsiones y sin convulsiones, respectivamente.

Se muestra en la figura 12 las dimensiones de las matrices creadas anteriormente, teniendo en cuenta que la estructura de clasificación del conjunto de entrenamiento y validación se llaman **ytrain** y **ytest**, respectivamente, en el código de programación.

```
Implementación de Red Neuronal Recurrente

El 70% de los pacientes que NO tienen convulsiones es:
El 70% de los pacientes que SI tienen convulsiones es:
Finalización de ingreso de los datos...
-----
xtrain es:
(418, 14427, 24)
(176, 14427, 24)
ytrain es: (418, 2)
ytest es: (176, 2)

Process finished with exit code 0
```

Figura 12: Dimensiones de estructuras de entrenamiento y validación

Para llevar a cabo la configuración de los hiperparámetros de la red neuronal, y tras la creación de los vectores de entrenamiento y validación, se procede a la selección de valores críticos que permitan a la red resolver y clasificar las señales de manera efectiva. Los elementos e hiperparámetros que intervienen en la configuración de una red neuronal incluyen el tipo de modelo, la arquitectura de la red neuronal, el número de neuronas, la tasa de aprendizaje, el tipo de optimizador y el dropout.

En esta fase del proceso, se delinear los valores específicos o parámetros que deben ser elegidos como parte de la configuración de los hiperparámetros de la red neuronal.

Se define el modelo como una secuencia de capas creando un modelo Secuencial y se añaden capas a la red neuronal hasta que la topología sea la deseada. Se evalúa que la capa de entrada tenga el número correcto de entradas. En este caso se utilizará una estructura de red conectada de tres capas: entrada, oculta y salida.

Un parámetro crucial es la elección del tipo de red neuronal que se implementará. En este caso, se optará por utilizar una red neuronal recurrente simple (**RNN**) para el entrenamiento, lo que proporcionará una primera aproximación a una posible solución para la clasificación de señales epilépticas. En consonancia con el tipo de red neuronal seleccionado, es necesario especificar el número de neuronas. Para el primer entrenamiento, se ha decidido emplear 64 neuronas para la tarea de clasificación.

Es necesario indicar cuántas señales van a ser analizadas por paciente, es decir, cual

es el tamaño de la matriz de entrenamiento. Este procedimiento se realizó cuando se crearon las matrices de estructura de entrenamiento y validación.

El Dropout es un hiper-parámetro que permite desactivar aleatoriamente un número de neuronas en el proceso de aprendizaje con el fin de evitar el sobre entrenamiento de la red. Se usará un valor de 0.2 para iniciar la clasificación de las señales.

La función de activación que se va a utilizar es la función sigmoid. Se elige esta función debido al mayor rendimiento comparada con otras funciones, además de asegurarse que la salida de red esté entre 0 y 1.

La función de pérdida a utilizar para el entrenamiento de la red neuronal es la función de pérdida logarítmica, definida en el software como **binary crossentropy**, la cual se usa con frecuencia para un problema de clasificación binaria, ideal para el presente caso de estudio.

El optimizador utilizado será el de **descenso de gradiente eficiente** o **adam** por su alta eficiencia en problemas de clasificación. Al definir el modelo con los hiper-parámetros mencionados anteriormente, se ejecuta sobre los datos de entrenamiento con el fin de modelar y/o ajustar a los datos cargados usando la función **fit**.

En el proceso de entrenamiento se realizarán ejecuciones para un número fijo de iteraciones usando el hiper-parámetro **epochs**. Por otro lado, el hiper-parámetro **batch size** establecerá el número de veces que se evalúa la red antes que se realice una actualización de peso. Para un primer ensayo de la red se utilizará un valor para **epochs** de 20 y **batch size** de 30. Estos valores se van modificando experimentalmente por ensayo y error. En la tabla 6 se muestra el valor de los hiper-parámetros asignados para una primera iteración.

Tabla 6: Valores asignados a los hiper-parámetros de la red neuronal

	<b>Hiper-parámetro</b>	<b>Valor/Tipo</b>
<b>1</b>	numero de neuronas	64
<b>2</b>	epochs	20
<b>3</b>	batch size	30
<b>4</b>	dropout	0.2
<b>5</b>	learning rate	0.001
<b>6</b>	Función de activación	sigmoid
<b>7</b>	Función de pérdida	binary_crossentropy
<b>8</b>	Optimizador	adam
<b>9</b>	Modelo	Sequential
<b>10</b>	Tipo de red	Simple_RNN

4. **Entrenamiento:** Una vez que se ha completado la configuración de todos los hiperparámetros de la red neuronal, se inicia el proceso de entrenamiento utilizando el conjunto de entrenamiento con el objetivo de obtener resultados significativos para la investigación. Durante esta etapa, existe la posibilidad de ajustar o modificar el valor de uno o más hiperparámetros con el fin de obtener diversas respuestas. Este enfoque permite explorar diferentes configuraciones y elegir los resultados más apropiados para el caso de estudio en cuestión.

Finalmente, se procede a evaluar el rendimiento de la red neuronal implementada. Sin embargo, durante la primera prueba bajo los hiperparámetros especificados y utilizando el conjunto de entrenamiento y validación proporcionado, se observa que el proceso de entrenamiento de la red neuronal no se ejecuta correctamente. Al examinar los errores arrojados, se identifica una incoherencia tanto en la lectura de los datos como en su procesamiento. Se sugiere que esta discrepancia puede deberse a una falta de coincidencia entre las dimensiones de la base de datos y las matrices de clasificación creadas previamente. Además, se señala que los parámetros que la red neuronal está evaluando también difieren de las dimensiones de la base de datos, lo que contribuye a la incongruencia observada. Es necesario abordar estas discrepancias para asegurar un entrenamiento efectivo y preciso de la red neuronal.

5. **Respuesta:** Se lleva a cabo un análisis detallado de las gráficas y valores resultan-

tes, de acuerdo con las métricas propuestas, tras completar el entrenamiento de la red neuronal. Este proceso de análisis permite evaluar el rendimiento y la eficacia del modelo, proporcionando información valiosa sobre la capacidad de la red para clasificar las señales con base en las métricas establecidas previamente.

### 3.4. Organización de la base de datos

En esta etapa de la investigación, se lleva a cabo una depuración de las señales. Es esencial examinar si hay errores en la implementación de la red neuronal para identificar cuáles de ellos están obstaculizando la ejecución del código. A diferencia del preprocesamiento de la base de datos, en esta sección se cuenta con un conocimiento más detallado de las señales que son irrelevantes para la clasificación. Esto se debe a un mayor entendimiento de cómo está distribuida la información, permitiendo la omisión de aquellas señales que no contribuyen de manera significativa a la investigación.

Tras ejecutar la red neuronal y constatar que el código implementado no se ejecutó correctamente durante el proceso de entrenamiento, se lleva a cabo una depuración en la base de datos. La principal razón de la falta de ejecución de la red neuronal radica en la lectura inadecuada de los datos. Además, la organización inapropiada de los mismos también impide el correcto funcionamiento de la red neuronal.

Para abordar este tipo de error, se realiza un análisis detallado de cómo están organizados los datos en los archivos `.txt`, prestando especial atención a sus dimensiones. Como se detalló en la sección **3.2**, el total de muestras a analizar es de 595 y se encuentran organizadas de la siguiente manera, donde la mayoría de las muestras sigue este patrón:

Las dimensiones de los archivos es de 3600 filas y 23 columnas. Las filas equivalen al número de muestras recolectadas en el test y las columnas muestran el número de canales que son leídos por medio de los electrodos. Se tiene la particularidad que no todos los archivos tienen las dimensiones descritas anteriormente, algunos archivos tienen 959, 9536, 14400 y 14427 muestras tomadas en el test; también hay variación en el número total de canales pasando de 23 a 24 para algunas muestras.

Con el objetivo de lograr homogeneidad en las dimensiones de todas las muestras, asumiendo que la falta de homogeneidad en los datos genera errores durante la ejecución del código, se procede a realizar un reajuste en las 595 muestras. Este reajuste implica estandarizar todas las muestras para que tengan dimensiones uniformes. Para lograr esto, se determina que todas las muestras tendrán un número constante de filas (14427) y columnas (24). Esta elección se basa en tomar el mayor número de muestras y canales disponibles, con el fin de no eliminar muestras que podrían ser relevantes en el proceso de clasificación. Finalmente, el reajuste se lleva a cabo rellenando las celdas vacías con el valor **0**. De esta manera, todas las muestras a analizar tendrán las mismas dimensiones, lo que facilitará la depuración del código y permitirá su ejecución para evaluar su comportamiento.

### **3.5. Evaluación del modelo de la red neuronal**

La red neuronal se evalúa en esta fase para determinar su rendimiento en la clasificación de señales utilizando la base de datos previamente mencionada. Se utilizarán los mismos hiperparámetros de configuración de la red neuronal, y se dará inicio a la ejecución del código implementado con el propósito de analizar su comportamiento.

Después de depurar la base de datos descrita en la sección anterior, se procede a la evaluación de la red neuronal. Antes de realizar la evaluación del programa de clasificación, es esencial definir el modelo de la red neuronal, que generalmente se conceptualiza como una secuencia de capas organizadas. Además, se debe especificar el número de neuronas en cada capa como el primer argumento, junto con la función de activación y otros parámetros necesarios para el correcto funcionamiento de la red neuronal.

En el transcurso de la ejecución, resulta esencial especificar las propiedades necesarias para la formación de la red. La evaluación y el entrenamiento de una red neuronal involucran la búsqueda del mejor conjunto de pesos para realizar predicciones específicas en un problema dado. Es imperativo indicar la función de pérdida del modelo para evaluar dicho conjunto de pesos, así como el optimizador que se empleará en el proceso. Estas decisiones son

cruciales para el desempeño efectivo de la red neuronal en la tarea de clasificación de señales.

Luego de asignar valores a los hiperparámetros, se registran los resultados generados por la configuración de la red con el propósito de determinar si dicha configuración logra clasificar las señales de manera correcta.

Hasta este punto, el modelo de la red ha sido definido. Sin embargo, es crucial ajustar dicho modelo a los datos cargados mediante una función llamada **fit()**. Durante este proceso de entrenamiento, se llevará a cabo un número fijo de iteraciones conocidas como **épocas** o **epochs**. Además, es necesario establecer el número de instancias que se evalúan antes de realizar una actualización de pesos en la red, lo cual se logra mediante el argumento **batch\_size**. Otro parámetro importante a considerar es la tasa de aprendizaje o **learning\_rate**, que determina la velocidad a la que el algoritmo alcanza las ponderaciones óptimas.

Una vez definidos todos los hiperparámetros y entrenada la red con el conjunto de entrenamiento, se procede a evaluar su rendimiento utilizando el conjunto de validación. Aunque es posible evaluar la red con el mismo conjunto de entrenamiento, hacerlo no proporcionaría una indicación útil del rendimiento, ya que la red ya estaría familiarizada con esos datos. La evaluación con el conjunto de validación permite una mejor comprensión de cómo la red se generaliza a datos no vistos durante el entrenamiento.

Finalmente, el modelo evalúa la pérdida utilizando los patrones de prueba, además de otras métricas especificadas. En este caso, se ha seleccionado la precisión de clasificación, sensibilidad y especificidad como métricas de interés. Estas métricas proporcionarán una comprensión detallada del rendimiento del modelo en la tarea de clasificación.

El primer resultado obtenido se observa en las figuras 13, 14 y 15 donde se muestra el modelo de pérdida, el modelo de exactitud y el resultado de la matriz de confusión cuando se utilizan 16 neuronas, un valor de epochs igual a 20 y un batch size de 10.

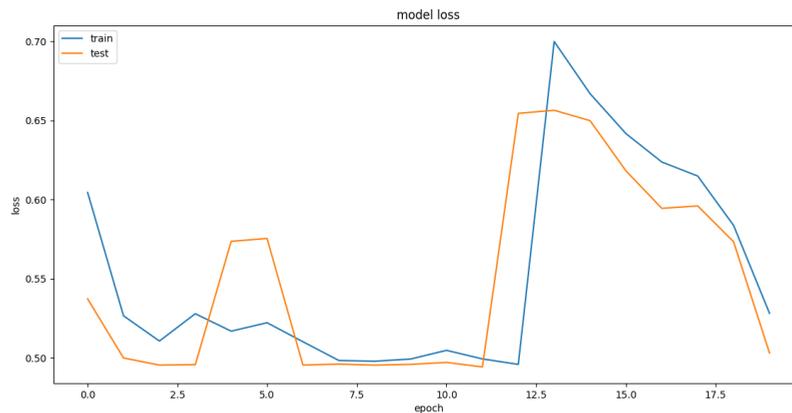


Figura 13: Modelo de pérdida usando 16 neuronas

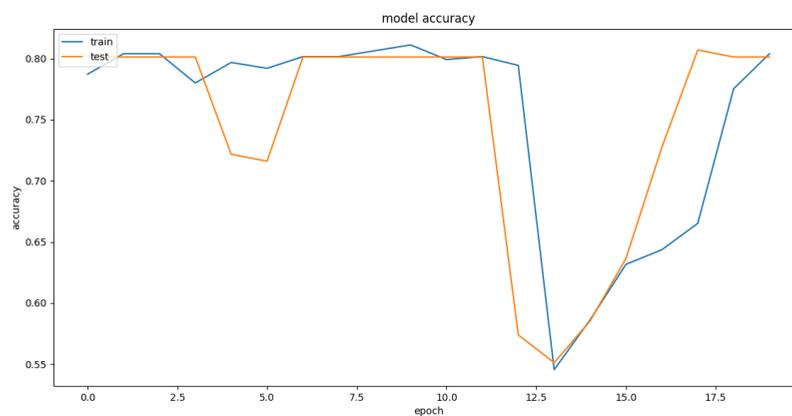


Figura 14: Modelo de exactitud usando 16 neuronas

	precision	recall	f1-score	support
class 0(Gesture 1)	0.81	1.00	0.89	141
class 1(Gesture 2)	1.00	0.03	0.06	35
accuracy			0.81	176
macro avg	0.90	0.51	0.47	176
weighted avg	0.84	0.81	0.73	176
[[141 0]				
[ 34 1]]				

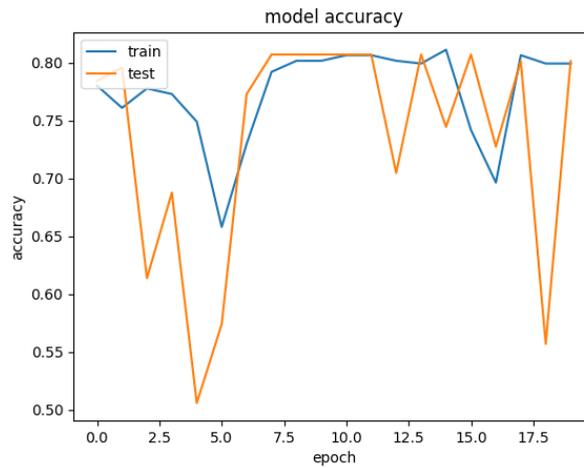
Figura 15: Matriz de confusión obtenida después del entrenamiento de la red neuronal

La tabla 7 presenta los hiperparámetros ajustados en cada iteración de la red neuronal con el fin de identificar una respuesta eficaz utilizando la base de datos actualmente disponible.

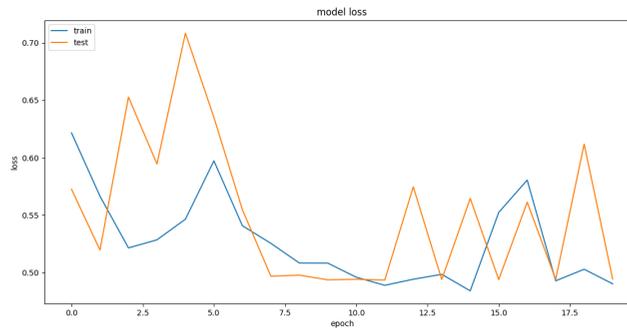
Tabla 7: Hiperparámetros modificados para el entrenamiento de la red neuronal

Learning rate	Optimizer	Activation function	Numero neuronas	Epochs	Batch size
0.001	SGD	Sigmoid	16	20	10
					20
					30
					40
					50
			32	20	10
					20
					30
					40
					50
			64	20	10
					20
					30
					40
					50
			128	20	10
					20
					30
					40
					50

De forma similar, las figuras 16, 17 y 18 muestran los modelos de precisión y pérdida cuando el valor de epochs es igual a 20 y el batch size de 10 cuando se varían el numero de neuronas de 32, 64 y 128. Las demás figuras obtenidas a partir de la variación de hiperparámetros descritos en la tabla 7, están alojadas en el enlace `First_training` ubicado en el repositorio de GitHub.



(a) Modelo de precisión con epochs=20 y batch size= 10

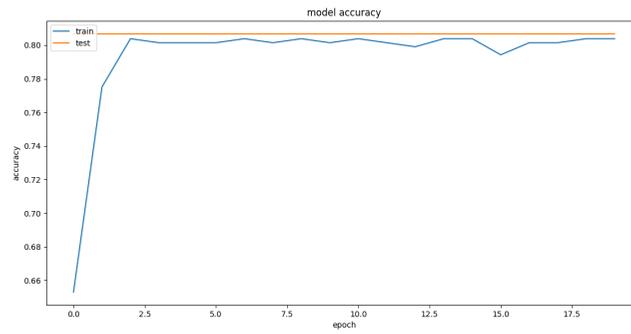


(b) Modelo de pérdida con epochs=20 y batch size= 10

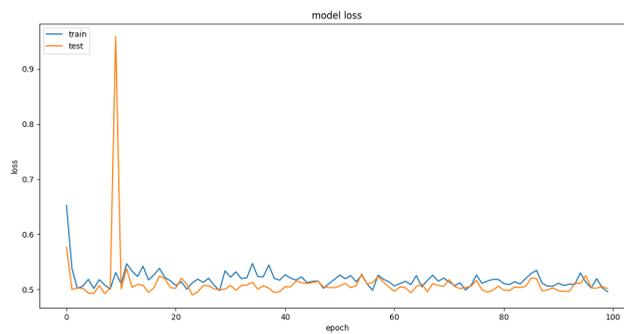
Figura 16: Resultados de entrenamiento de la red neuronal usando 32 neuronas

La observación de la Figura 15 revela el resultado de la matriz de confusión, indicando que la red neuronal no está clasificando las señales de manera precisa. La interpretación del resultado es la siguiente:

De las 141 señales sin convulsiones, todas fueron correctamente clasificadas como tales. En contraste, de las 35 señales con convulsiones, 34 fueron incorrectamente clasificadas como sin convulsiones, y solo 1 señal fue correctamente identificada como una señal con convulsiones. Por otro lado, las figuras de precisión y pérdida no muestran patrones significativos a medida que avanza el proceso de entrenamiento y validación, por lo que no resultan útiles.

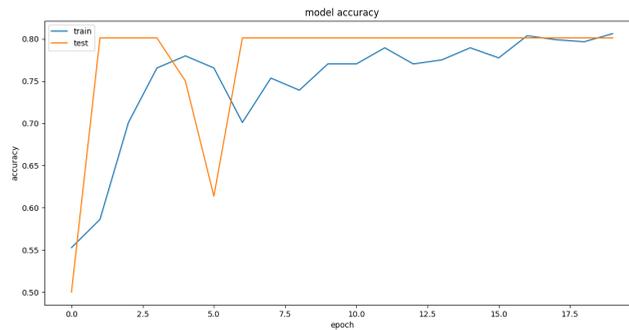


(a) Modelo de precisión con epochs=20 y batch size= 10

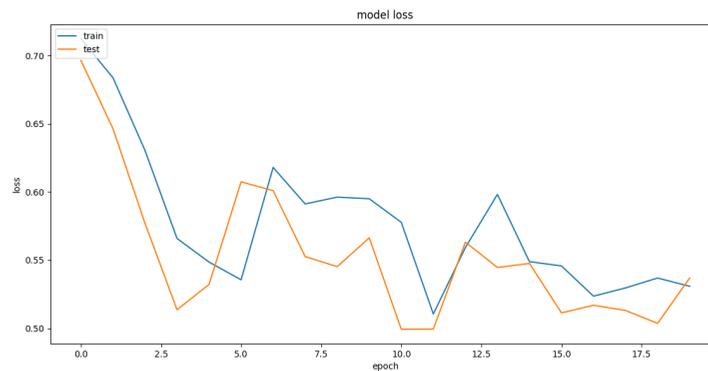


(b) Modelo de pérdida con epochs=20 y batch size= 10

Figura 17: Resultados de entrenamiento de la red neuronal usando 64 neuronas



(a) Modelo de precisión con epochs=20 y batch size= 10



(b) Modelo de pérdida con epochs=20 y batch size= 10

Figura 18: Resultados de entrenamiento de la red neuronal usando 128 neuronas

Al igual que las figuras 13 y 14, las nuevas figuras obtenidas a partir de la variación de hiperparámetros y el número de neuronas no muestran mejoras; y mucho menos lo hacen las matrices de confusión obtenidas, ya que todas arrojaron el mismo resultado que se observa en la figura 15.

### 3.6. Descomposición de Señales

En respuesta a la observación de que la red neuronal implementada no logra clasificar las señales de manera precisa, se recurre a la aplicación de la Descomposición Empírica de Modos (EMD). Esta técnica de descomposición de señales permite separar las señales en componentes con diferentes frecuencias, efectuando un tipo de filtrado de manera natural y preparando las señales para el proceso posterior a cargo de la red neuronal. En este

caso, se empleará nuevamente el software Matlab para llevar a cabo la descomposición.

El propósito de esta nueva etapa es reducir la complejidad de la información contenida en la base de datos. La EMD, a través de las Funciones de Modo Intrínseco (IMF), segmenta las señales de interés de las que no lo son. Las IMFs proporcionan información en el dominio de la frecuencia, permitiendo la identificación de frecuencias irrelevantes y aquellas relevantes para la investigación. Como se discutió en el capítulo I, las bandas de frecuencia características de la actividad cerebral son esenciales para la detección de patologías, especialmente en el caso de convulsiones epilépticas. Este enfoque busca destacar las frecuencias de interés, mejorando así la capacidad de la red neuronal para analizar y clasificar las señales de manera más efectiva.

Las bandas de frecuencia establecidas por Berger fueron: alfa ( $\alpha$ ), beta ( $\beta$ ), delta ( $\delta$ ), gamma ( $\gamma$ ) y tetha ( $\theta$ ), las cuales establecen estados de actividad o inactividad cerebral dependiendo de la banda donde se encuentren. Por lo tanto, se necesitan conocer y obtener las frecuencias de interés para el caso de estudio actual, con el propósito de realizar una nueva clasificación de convulsiones epilépticas usando un conjunto de señales con menor distorsión que los obtenidos en etapas anteriores.

Al evaluar la red neuronal bajo los hiper-parámetros impuestos en la etapa anterior, se observan errores en el resultado de clasificación. Se observa que la red está clasificando correctamente las señales no epilépticas, pero al evaluar las señales que padecen convulsiones, la red nuevamente las clasifica como señales no epilépticas.

Esta decisión motiva la elección de realizar la descomposición de las señales. Como se abordó en el capítulo II, donde se presentaron teóricamente los métodos de descomposición, la EMD, mediante las IMFs, posibilita un filtrado natural de las señales al separarlas en modos de oscilación físicamente significativos. Sin embargo, para llevar a cabo este procedimiento, se requiere reorganizar y depurar nuevamente la base de datos. Este proceso tiene como objetivo reducir información que carece de relevancia para el método de descomposición de señales, optimizando así la aplicación efectiva de la EMD.

Debido a que la descomposición de señales forma parte del cumplimiento del primer

objetivo específico, los resultados obtenidos en esta sección se mostrarán en el capítulo IV.

### **3.7. Clasificación de convulsiones epilépticas con la base de datos actualizada**

Después de realizar la descomposición de las señales, se procede a reconfigurar la arquitectura de la red neuronal utilizando los resultados obtenidos en ese proceso. Este ajuste es fundamental para llevar a cabo la tarea de clasificación de señales epilépticas de manera precisa y efectiva. En esta fase de la investigación, la base de datos utilizada en el preprocesamiento y organización inicial no será empleada, ya que los datos han sido transformados mediante técnicas de descomposición. En su lugar, se introduce un nuevo conjunto de datos específico para la reconfiguración de la red neuronal. El propósito de esta nueva fase es evaluar la capacidad de la red para realizar una clasificación más precisa de las señales adquiridas a través de las IMFs obtenidas previamente. Este enfoque ofrece una perspectiva renovada y optimizada para la tarea de clasificación.

Para la clasificación de señales, se emplearán las arquitecturas de red mencionadas previamente, y además, se añadirán librerías y modelos que garanticen el óptimo funcionamiento de la red neuronal. Esta etapa de la investigación se centrará en una configuración más detallada de la red neuronal, llevando a cabo un mayor número de iteraciones con la expectativa de obtener resultados que destaquen por altas métricas de aprendizaje. El enfoque será profundizar en los ajustes de la red para maximizar su rendimiento y eficacia en la clasificación de las señales, buscando así resultados más precisos y confiables.

Luego de completar las etapas previamente mencionadas, se presenta el diagrama de bloques en la figura 19, el cual detalla paso a paso el proceso a seguir para llevar a cabo la clasificación y descomposición de señales EEG. Este diagrama ofrece una visión integral del flujo de trabajo, destacando las fases cruciales y las interconexiones entre ellas, proporcionando así una guía visual clara para la comprensión del procedimiento implementado en la investigación.

Al igual que en la fase de descomposición de señales, los resultados derivados de la clasificación de convulsiones epilépticas mediante redes neuronales artificiales contribuyen al logro de un objetivo específico, cuyos hallazgos serán detallados en el próximo capítulo.

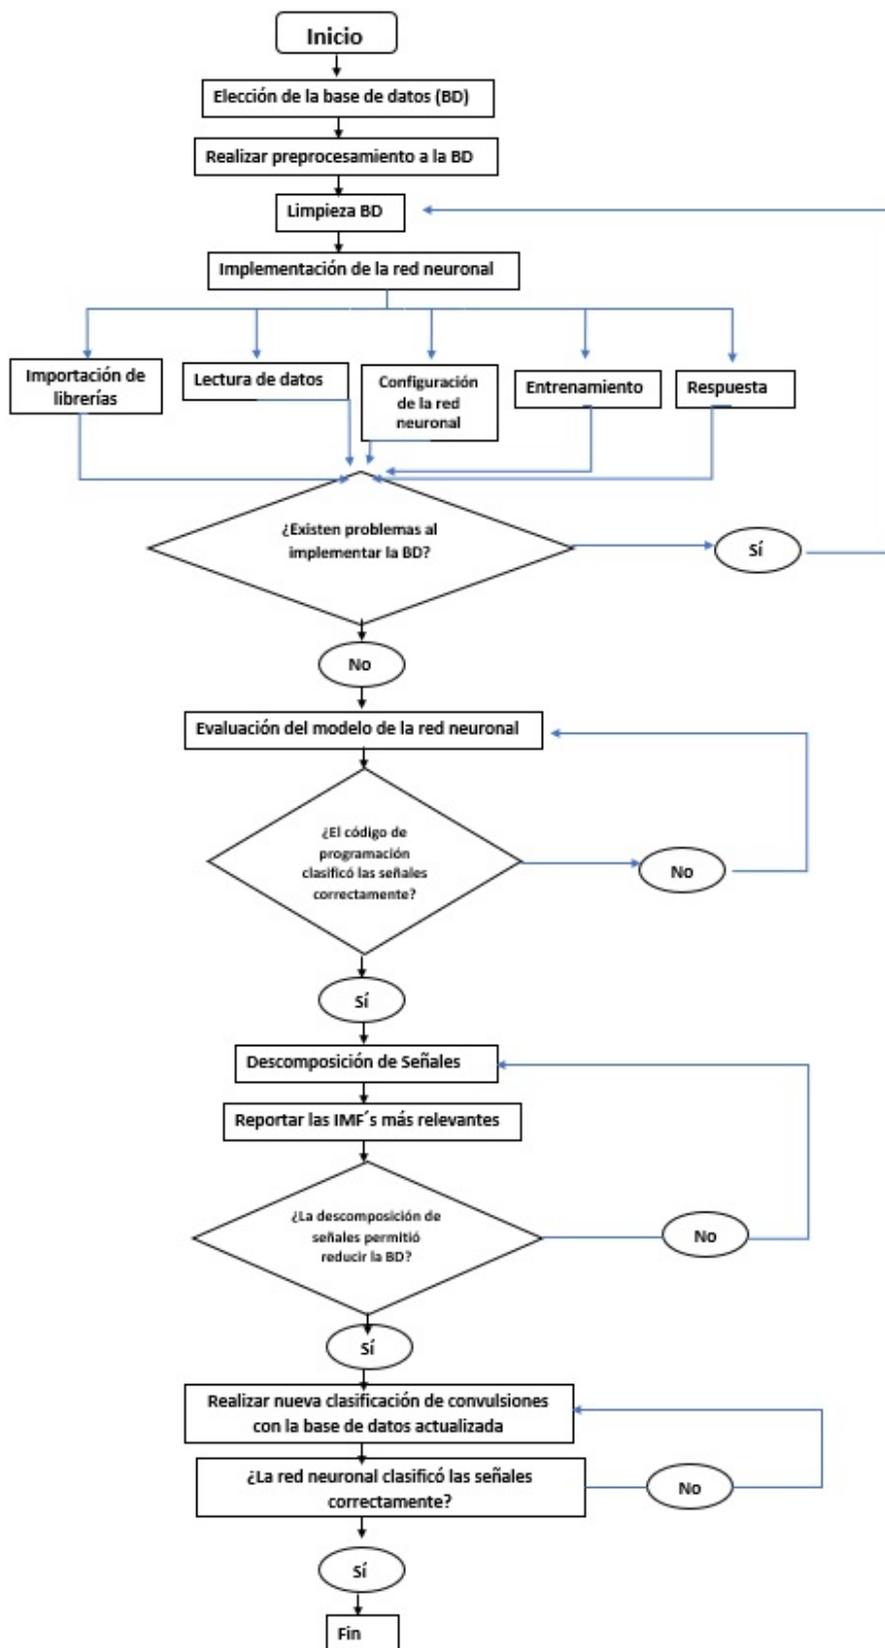


Figura 19: Diagrama de bloques de la configuración de una red neuronal

## 4. Presentación de Resultados

En este capítulo se mostrarán los resultados obtenidos en el presente trabajo de grado para dar cumplimiento a los objetivos específicos propuestos en el capítulo I.

### 4.1. Descomposición de señales empleando EMD

Partiendo de la base de datos delineada en el capítulo III y a continuación, tras la organización previamente descrita en ese mismo capítulo, se inicia la etapa de descomposición de señales empleando el enfoque metodológico de la Descomposición Empírica de Modos (EMD). Para iniciar este proceso, se emplea el software computacional Matlab, donde se ejecuta el código desarrollado específicamente para esta tarea. El procedimiento para obtener las IMFs se describe a continuación.

La base de datos descrita previamente, cuenta con 595 registros de pacientes. Cada registro se compone de una matriz de datos con 14427 filas que representan las mediciones obtenidas a partir de pruebas EEG realizadas en un periodo de tiempo específico y 24 columnas que representan los canales a los cuales se les realizó la prueba. Con el propósito de homogeneizar las dimensiones de todas las muestras, se realizaron rellenos de ceros en aquellas celdas vacías.

Para realizar la descomposición de señales, se observa que todas las celdas rellenas con el valor de cero no aportan información relevante en la investigación, ya que el algoritmo de EMD segmentará cada señal en componentes de frecuencia, y al explorar las filas y columnas con valores de cero en sus celdas, no se obtendrán resultados significativos.

Por lo tanto, se hace imperativo eliminar estos valores nulos del conjunto de datos, reduciendo la base de datos únicamente a aquellos valores no nulos, que son los más relevantes para la investigación. En concordancia con lo mencionado anteriormente, se procede a depurar las celdas que contienen ceros.

Como se mencionó en la sección 3.4, los archivos de la base de datos presentan diferentes dimensiones tanto en el número de filas como de columnas siendo 3600 el número de filas

y 23 de columnas la dimensión mas común en la base de datos. Por consiguiente, se crea un nuevo conjunto de datos con estas dimensiones, eliminando todos los archivos que difieren de estas especificaciones. En consecuencia, la base de datos se ha reducido de 595 a 437 muestras en total. De estas muestras, 357 corresponden a pacientes sin convulsiones, mientras que 80 muestras corresponden a pacientes con diagnóstico de convulsiones epilépticas. La tabla 8 muestra la información recopilada respecto a la base de datos y en el enlace `Database_to_decompose` ubicado en el repositorio de GitHub se encuentran disponibles los archivos mencionados.

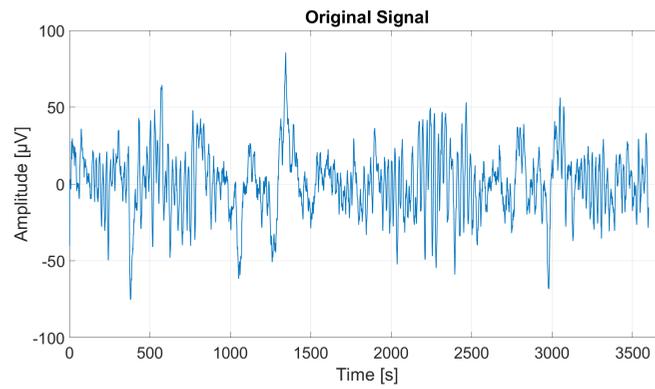
Tabla 8: Información de la base de datos

<b>Base de datos</b>	<b>Señal con convulsiones</b>	<b>Señal sin convulsiones</b>	<b>Total</b>
<b>Original</b>	<b>475</b>	<b>120</b>	<b>595</b>
<b>Modificada</b>	<b>357</b>	<b>80</b>	<b>437</b>

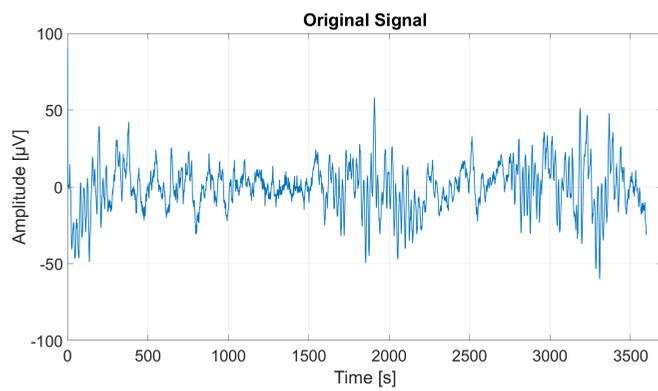
Con el objetivo de someter a una evaluación sistemática la efectividad del proceso de descomposición, se procede al análisis detallado de las 437 señales obtenidas de los pacientes. Inicialmente, se lleva a cabo la lectura de todas las señales en su estado original y para evaluar el comportamiento del método de descomposición, se muestra el comportamiento de la señal en 3 pacientes como se muestra en la figura 20.

A continuación, se despliega el procedimiento de EMD, un enfoque reconocido por su capacidad de resolución intrínseca en el dominio temporal-frecuencial. Este proceso culmina con la obtención de las IMFs correspondientes a cada señal, representando una descomposición adaptativa. La EMD, al actuar como una serie de filtros adaptativos, logra descomponer la señal original en componentes de distintas frecuencias, ofreciendo una representación multi resolutive de las señales subyacentes de interés. En la figura 21 se muestran tres de los resultados obtenidos al aplicar EMD a las señales originales. Al descomponer las señales, se tendrán diferentes bandas de frecuencia de las cuales se elegirán las bandas significativas para el caso de estudio en mención.

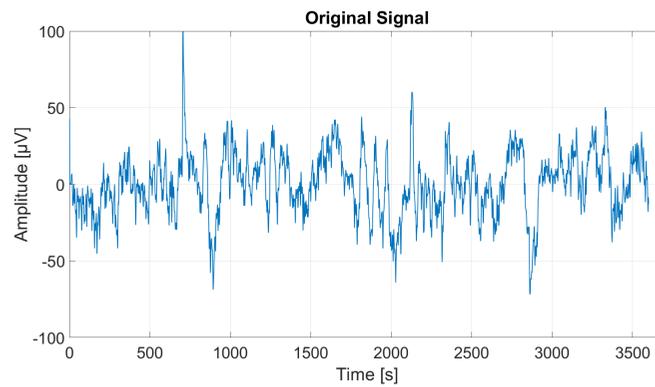
Con el código de programación implementado en Matlab, que descompone las señales EEG mediante las IMFs, se inicia el proceso para hallar todos los componentes significativos



(a) Señal 1.



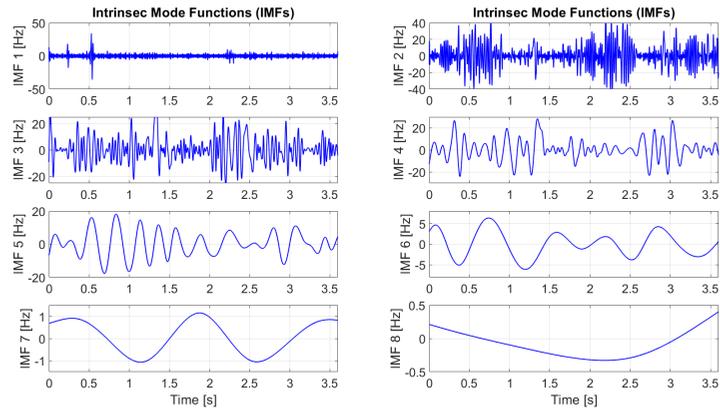
(b) Señal 2.



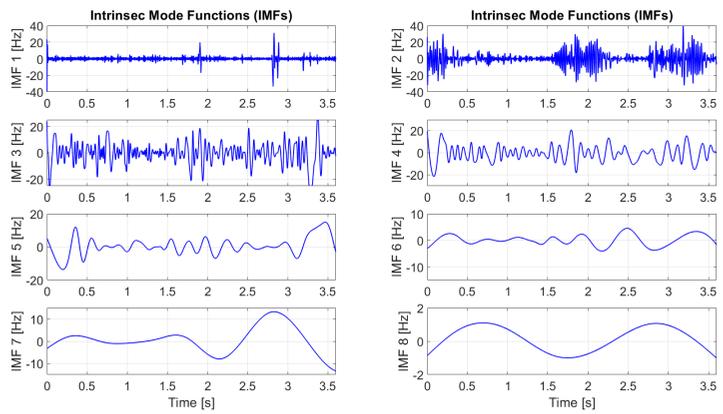
(c) Señal 3.

Figura 20: Señal original de diferentes pacientes.

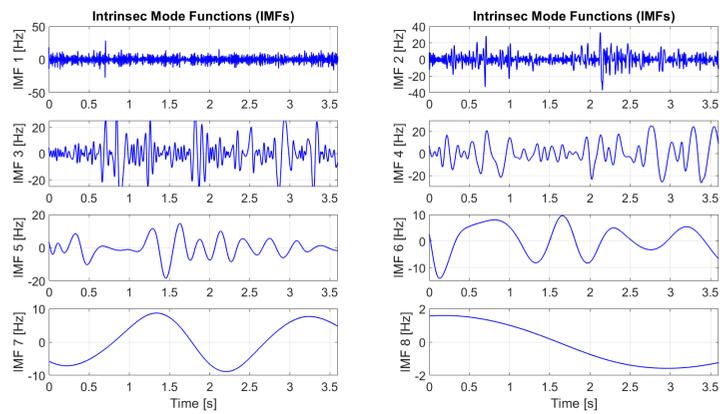
para la investigación mediante las señales existentes en la modificada base de datos. Con la obtención de las IMFs para las señales presentes en la base de datos, se dá cumplimiento al primer objetivo específico del presente trabajo de grado.



(a) Señal 1.



(b) Señal 2.

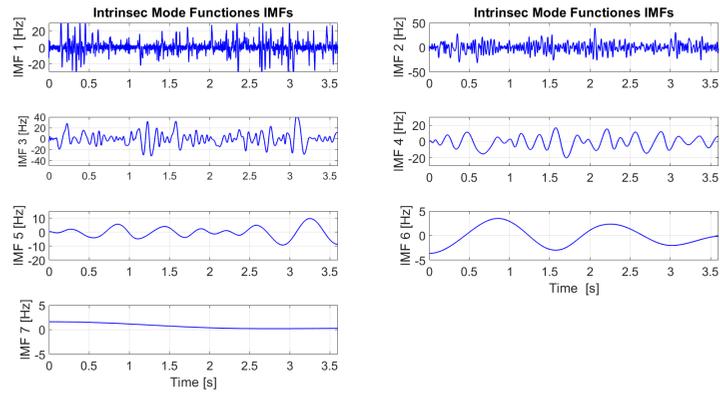


(c) Señal 3.

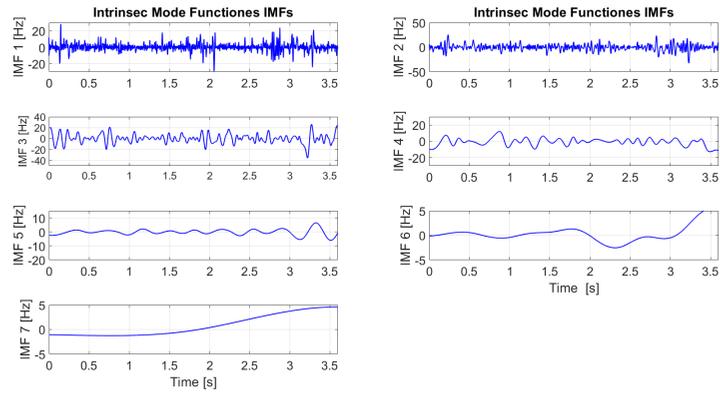
Figura 21: Análisis de señal obtenidas con el EMD.

A partir de la técnica de EMD llevada a cabo en la sección anterior, se procede a implementar el Ensemble Empirical Mode Decomposition (EEMD), una técnica más avanzada que mejora la robustez y la estabilidad de la descomposición original. El EEMD incorpora un enfoque de conjunto al introducir variaciones controladas y la adición de ruido blanco en múltiples iteraciones de la descomposición EMD. Este proceso tiene aplicaciones significativas en la detección de convulsiones epilépticas, ya que las señales EEG asociadas con epilepsia a menudo exhiben patrones no lineales y no estacionarios. El EEMD ayuda a mitigar artefactos y mejora la capacidad de identificar componentes intrínsecas de la señal, lo que puede ser fundamental para la detección precisa de eventos epilépticos en registros EEG.

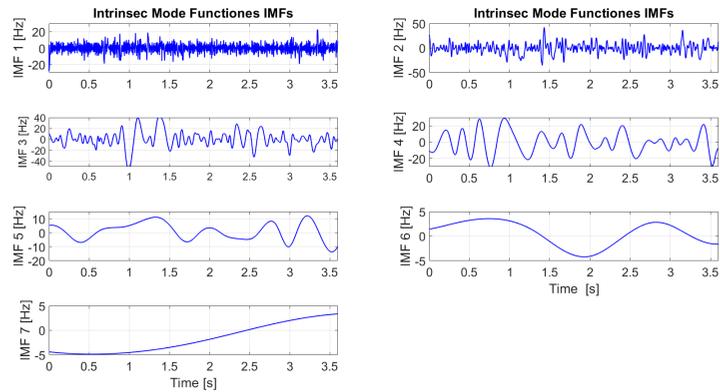
La figura 22 muestra los resultados obtenidos de la descomposición donde se adiciona ruido gaussiano a cada una de las señales para obtener una mejor separación entre las IMFs y reducir el modo mixto.



(a) Signal 1



(b) Signal 2



(c) Signal 3

Figura 22: Análisis de señales usando EEMD

## 4.2. Selección de variables a partir del análisis realizado con el EMD

En el marco del cumplimiento del primer objetivo específico, se procedió a realizar la descomposición de las señales mediante el algoritmo de EMD. Esta descomposición fue aplicada de manera individual a cada uno de los 23 canales correspondientes a los 437 pacientes registrados en la base de datos. Con el propósito de definir la selección de variables, se opta por el método más adecuado para obtener resultados que serán utilizados para alimentar la red neuronal. Existen diversas técnicas disponibles para lograr este objetivo, algunas de las cuales se fundamentan en el análisis de energía, entropía y frecuencia, destacando como los enfoques más pertinentes y relevantes en este contexto.

En el contexto específico de este estudio, se elige realizar la selección de variables mediante un análisis centrado en la frecuencia. Para llevar a cabo este proceso, se hacen uso de los resultados derivados del cumplimiento del primer objetivo específico, que consiste en la obtención de las IMFs de cada una de las muestras contenidas en la base de datos.

De acuerdo con lo establecido en el capítulo I, donde se detallaron las bandas de frecuencia características de la actividad cerebral, tal como las describió Berger, se identificó que estas bandas oscilan entre 0 Hz y 40 Hz. Estas bandas eran fundamentales para el análisis de estados propicios para la aparición de convulsiones epilépticas.

Al examinar los resultados obtenidos a través de EMD y por medio de las IMFs obtenidas que se muestran en la figura 21, se observa que estos valores de frecuencia se extienden aproximadamente hasta los 50 Hz. Basándose en un estudio exhaustivo del estado del arte y considerando los antecedentes de esta investigación en particular, se concluye que las bandas de interés se limitan hasta los 20 Hz. Más allá de este punto, aunque las bandas de frecuencia poseen relevancia, no aportan una significativa contribución al diagnóstico de la epilepsia.

La previa descomposición de las señales proporcionó entre 7 y 8 IMFs por cada canal de registro de cada paciente como se observa en la figura 21. En la figura 23 se muestran las

IMFs obtenidas para un paciente con convulsiones epilépticas.

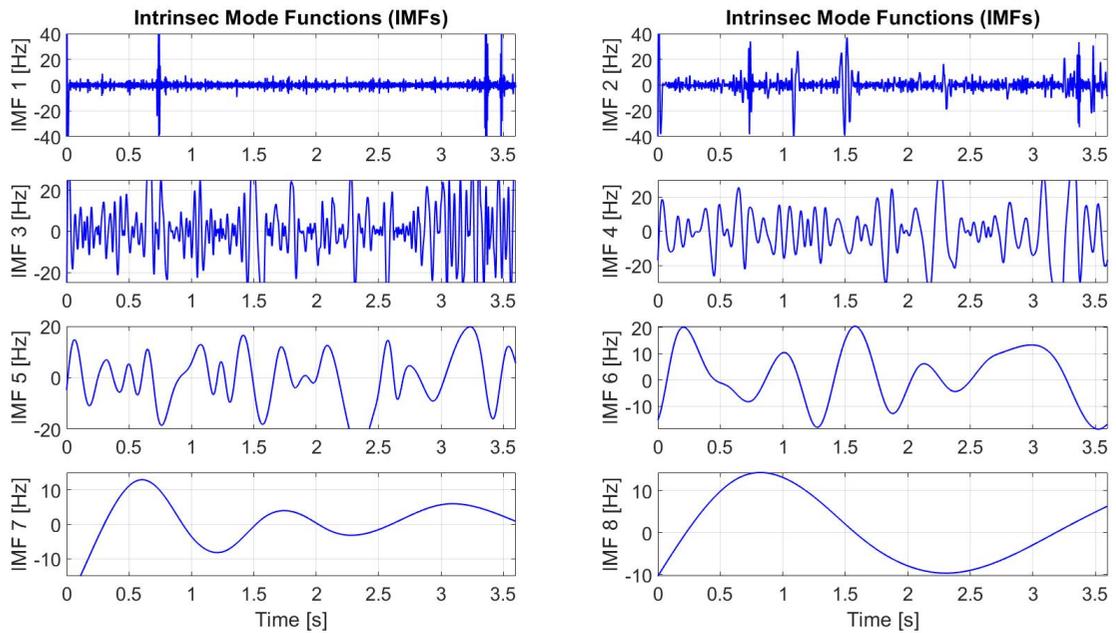


Figura 23: IMFs obtenidas de un paciente con epilepsia

En la anterior figura se logran apreciar las IMFs obtenidas al descomponer la señal. Es importante notar que la IMF1 y IMF2 exhiben exclusivamente actividad de ruido sin ninguna actividad de origen claramente identificable. Por otro lado, las IMF3 y IMF4 revelan una separación mas definida entre modos. Sin embargo, es a partir de la IMF5 donde las oscilaciones se tornan visibles con mayor claridad. Con el objetivo de efectuar una selección de variables apropiada, y teniendo en cuenta que las bandas de frecuencia cruciales para el presente estudio no exceden los 20 Hz, se determina que las IMFs 1 a la IMF4 no aportan información significativa, pudiendo considerarse como ruido presente en la señal. Por otro lado, desde la IMF5 hasta la IMF8, se observan períodos en los cuales las frecuencias obtenidas permiten una mejor visualización de los resultados, mostrando de manera clara valores máximos que posiblemente corresponden a momentos de crisis epilépticas en los pacientes. En consecuencia, a partir de este punto, se empleará la información contenida en las IMFs de la 5 a la 8, ya que son los datos que han sido sometidos a un meticuloso procesamiento mediante las técnicas de descomposición de señales previamente aplicadas,

junto con un riguroso proceso de selección y filtrado de variables.

Con la obtención de las IMFs para cada uno de los pacientes de la base de datos, también se obtiene la Frecuencia Instantánea (IF). A continuación, en la figura 24 se presentan las frecuencias instantáneas derivadas del análisis realizado mediante el método EMD para el mismo paciente que se mostró en la figura 23.

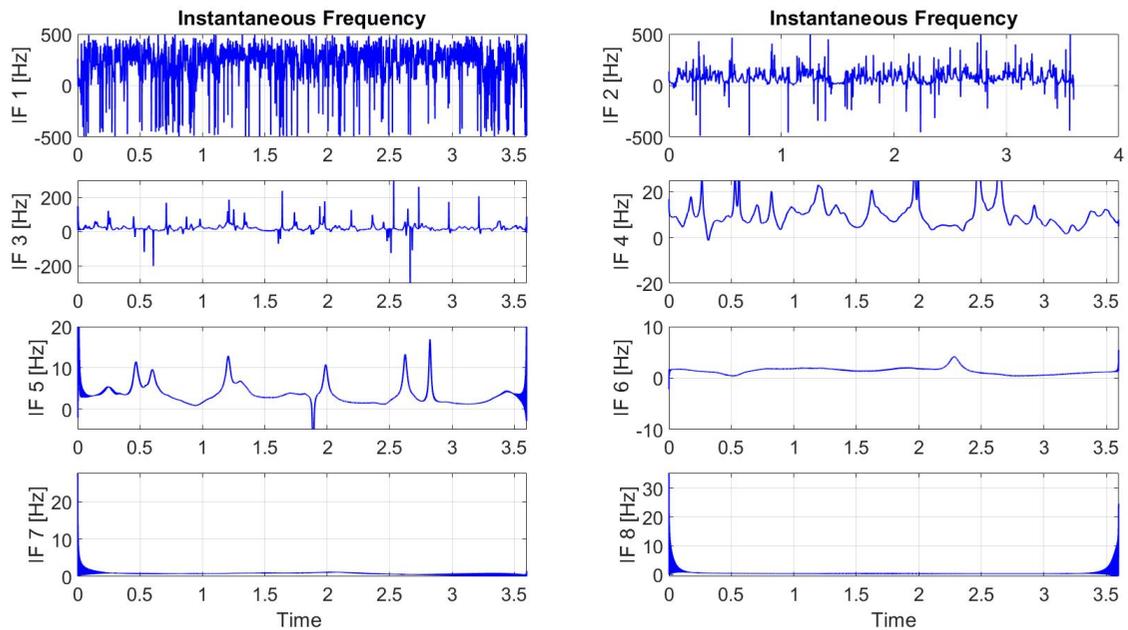


Figura 24: IFs obtenidas de un paciente con epilepsia

De manera congruente con lo previamente expuesto, las IF1 hasta la IF4 revelan la presencia de ruido en la señal, lo que plantea desafíos en la interpretación de los resultados. En contraste, a partir de la IF5 hasta la IF8 se logra una visualización clara de los picos representativos de las convulsiones epilépticas, lo que facilita la identificación de cambios en la señal en momentos específicos de tiempo. La IF5 muestra oscilaciones más claras que pueden

Mediante la depuración de las IMFs se logra satisfacer el segundo objetivo específico, que consiste en la selección de variables cruciales a partir de bandas de frecuencia específicas. Estas variables depuradas se utilizan para alimentar a la red neuronal con el propósito de

llevar a cabo una precisa clasificación de convulsiones epilépticas.

### **4.3. Clasificación automática de señales epilépticas a partir del uso de redes neuronales artificiales**

Finalizada la selección de variables en torno a las frecuencias derivadas de la descomposición a través del EMD, se inicia nuevamente con la clasificación de señales mediante la red neuronal.

Como se dijo anteriormente, se eligen las IMFs mas significativas para el presente caso de estudio siendo las que se ubican desde la posición IMF5 hasta la IMF8. En esta etapa de la investigación no se usará la base de datos que fue depurada y procesada en etapas anteriores, sino que solamente se seleccionan las variables que tienen mas relevancia en el proceso de clasificación.

En este punto de la investigación, el código utilizado para clasificar las señales mediante la red neuronal, ha sido modificado con el objetivo de lograr mejores rendimientos.

El primer parámetro modificado fue el modelo de la red neuronal, en este caso se cambio la red neuronal recurrente (RNN) por una Long Short-Term Memory (LSTM), tipo específico de arquitectura de RNN diseñada para abordar el problema de las dependencias a largo plazo en secuencia de datos.

Un hiperparámetro modificado fue el optimizador, se cambió de SGD (Stochastic Gradient Descent) a Adam (Adaptative Moment Estimation), pues de acuerdo a la literatura encontrada, este optimizador adapta la tasa de aprendizaje de forma individual para cada parámetro del modelo. Utiliza estimaciones del primer y segundo momento del gradiente para ajustar automáticamente la tasa de aprendizaje en cada parámetro permitiendo una adaptación mas dinámica a la variabilidad de los gradientes en diferentes dimensiones. La función de activación y el modelo de pérdida siguen siendo los mismos ya que muestran buenos resultados cuando se maneja en problemas de clasificación.

Es esencial señalar que, en función de los resultados derivados de la selección de varia-

bles mediante el análisis realizado con el EMD, cada uno de los archivos resultantes se sometió a un proceso de normalización y escala. Estos archivos se muestran en el archivo `Database_with_IMFs_normalized_and_scaled` ubicado en el repositorio de GitHub. Este procedimiento se llevó a cabo con la finalidad de alcanzar una clasificación óptima de las señales.

Con lo mencionado anteriormente, se procede a realizar nuevamente el entrenamiento de la red neuronal, bajo las condiciones impuestas anteriormente. La configuración de la red neuronal está compuesta por los siguientes pasos:

- Importación de librerías: se ingresan todas las librerías y módulos necesarios que se utilizan comunmente en el ámbito del aprendizaje automático y la manipulación de datos.
- Lectura de señales: en el contexto de procesamiento de señales, la lectura de datos implica la adquisición y comprensión de datos provenientes de información contenida en señales. Se ingresará dos conjuntos de datos: señales con epilepsia y sin epilepsia.
- Concatenar los datos de entrada: esta parte de código concatena dos conjuntos de datos creando una matriz que apila verticalmente las matrices leídas en la lectura de datos. Su forma será determinada por las dimensiones de las matrices originales.
- Creación de matriz binaria de salida: creación de una matriz binaria que representa las etiquetas de clase para los conjuntos de datos. Estas variables se utilizan posteriormente para crear la matriz binaria de salida que contendrá ceros y unos representando las clases correspondientes.
- Submuestreo de clases: se realiza un muestreo equitativo de clases positivas y negativas para abordar el desbalance en el conjunto de datos. Este proceso puede ayudar a mejorar el rendimiento del modelo en presencia de desbalances en el conjunto de datos.
- División de conjuntos de entrenamiento y prueba: esta sección lleva a cabo la partición de los conjuntos de datos en grupos de entrenamiento y prueba. Se asignan

porcentajes específicos para cada conjunto garantizando una distribución adecuada que respeta la proporción establecida.

- Escalamiento: se realiza el escalado de características ajustando a los datos de entrenamiento y transforma ambos conjuntos de datos de acuerdo con ese ajuste.
- Definición de modelo de red: se ajusta la red neuronal de acuerdo a parámetros y arquitecturas según características específicas de los datos.
- Visualización de probabilidades: predicciones realizadas en el conjunto de prueba para convertir las probabilidades en etiquetas.
- Respuestas de aprendizaje: visualización de métricas para evaluar el rendimiento de un modelo de clasificación.

En el archivo: `leandro_script2.py` del repositorio de GitHub se encuentra el código modificado para realizar las iteraciones.

En la tabla 9 se muestran los resultados obtenidos cuando se varía los hiperparámetros epochs y batch size, teniendo en cuenta que se empezó el entrenamiento de la red neuronal con 16 neuronas en la capa LSTM.

Con esta nueva configuración de la red neuronal se evidenciaron cambios en las métricas propuestas y aunque sus porcentajes de acierto son aleatorios, no son concluyentes. Para mejorar estos resultados, se introduce una nueva capa en la red neuronal. Esta capa denominada Bidireccional LSTM poseen ventajas en tareas que implican secuencia de datos.

En relación al código, agregar una capa adicional a la red neuronal solo requiere la inclusión de dos líneas de código en la estructura actual. El código modificado se encuentra en `script_with_2_layers.py` ubicado en el repositorio de GitHub. Efectuadas estas modificaciones se dispone a realizar iteraciones variando los mismos hiperparámetros mencionados antes y en la tabla 10 se muestran los resultados.

Tabla 9: Resultados de entrenamiento de la red neuronal usando IMFs normalizadas

Num. de capas	Epochs	Batch size	Accuracy [%]	Sensitivity [%]	Specificity [%]
1	10	16	48	0	100
		32	51	100	0
		64	51	5.8	1
		128	45	0	93
		256	54	35	75
	20	16	48	94	0
		32	54	100	62.5
		64	51	41	62.5
		128	51	100	0
		256	50	100	0
	30	16	51	100	0
		32	39	11	68.5
		64	39	5.8	75
		128	51	100	0
		256	54	88	18

Tabla 10: Resultados de entrenamiento de la red neuronal adicionando capa BiDirectional LSTM

Num. de capas	Epochs	Batch size	Accuracy [%]	Sensitivity [%]	Specificity [%]
2	10	16	51	0	100
		32	45	0	91.6
		64	54	80	33
		128	51	41	62.5
		256	50	0	100
	20	16	54	100	62.5
		32	50	100	0
		64	39	5.8	75
		128	51	100	0
		256	48	0	100
	30	16	48	100	0
		32	51	100	0
		64	53	86	10
		128	54	100	62.5
		256	50	100	0

La inclusión de una capa Bidireccional LSTM en la red neuronal no parece conducir a

mejoras significativas en comparación con los resultados anteriores. En consecuencia, se procede a analizar las posibles causas de estas limitaciones.

Dado el desempeño insatisfactorio observado en las iteraciones de la red neuronal, tanto con estructuras simples como más complejas, se procede a realizar un análisis exhaustivo para comprender las causas subyacentes de estos resultados adversos.

Como se expuso anteriormente, es imperativo llevar a cabo un nuevo análisis para identificar las razones por las cuales la red neuronal no logra clasificar las señales de manera precisa. A partir de la configuración más reciente de la red neuronal y empleando los archivos obtenidos mediante la descomposición de las señales, se inicia un proceso exhaustivo de captura de posibles fallos, información irrelevante o datos que pudieran haberse pasado por alto en las etapas previas del procedimiento.

Se evidencia que uno de los pasos dentro de la configuración de la red neuronal consiste en realizar el muestreo de las clases. En particular, este proceso implica tomar muestras de la clase minoritaria con el objetivo de equilibrar las proporciones entre las clases. Sin embargo, esta estrategia conlleva un inconveniente, ya que al realizar el muestreo, quedan muy pocas muestras disponibles para entrenar la red neuronal. Esta limitación dificulta que la red pueda aprender patrones característicos de manera efectiva, dado el reducido conjunto de datos con el que cuenta.

Para abordar esta problemática en el contexto de la clasificación de señales, resulta esencial implementar un proceso de sobre-muestreo en la base de datos original. En este escenario, dado que la clase minoritaria corresponde a las señales con convulsiones epilépticas, se procederá a realizar el sobre-muestreo específicamente en esta clase, con el objetivo de igualarla en tamaño a la clase mayoritaria. Este enfoque busca mitigar la escasez de datos en la clase con convulsiones epilépticas, permitiendo así que la red neuronal disponga de un conjunto de entrenamiento más equilibrado y propicio para aprender de manera más efectiva los patrones distintivos presentes en las señales.

Se procede a llevar a cabo el sobre-muestreo de las clases con el propósito de abordar los bajos niveles observados en las métricas propuestas en el presente trabajo de investiga-

ción. Para alcanzar este objetivo, es imperativo desarrollar un código de programación que posibilite el sobre-muestreo efectivo de las señales de interés. En el archivo `oversampling_minor_class.py` del repositorio de GitHub se muestra el código usado que permitió equilibrar las clases satisfactoriamente.

Este procedimiento resulta en una base de datos actualizada y equilibrada, lista para ser utilizada en el entrenamiento de la red neuronal. No obstante, antes de llevar a cabo el entrenamiento, se realizarán operaciones adicionales que permitan filtrar las señales más relevantes. La tabla 11 muestra los valores antiguos y actuales de la base de datos.

Tabla 11: Valores antiguos y actuales de la base de datos después del sobremuestreo

	<b>Señales con epilepsia</b>	<b>Señales sin epilepsia</b>
<b>Base de datos desbalanceada</b>	<b>357</b>	<b>81</b>
<b>Base de datos balanceada</b>	<b>357</b>	<b>357</b>

Ahora se necesita realizar nuevamente la descomposición de las señales a este nuevo conjunto de datos con el objetivo de encontrar los valores mas relevantes en la investigación de convulsiones epilépticas. En el archivo `emd_dataset_new.py` ubicado en el repositorio de GitHub se muestra el código utilizado para descomponer las señales.

## 5. Discusión de los Resultados

En el presente capítulo se presenta el análisis derivado de cada uno de los procedimientos realizados en el trabajo de investigación.

### 5.1. Primer entrenamiento de la red neuronal

A partir de los resultados obtenidos tras la aplicación del preprocesamiento a la base de datos y la subsiguiente clasificación de las señales, se evidencia que la red neuronal no logró discernir de manera precisa las señales asociadas a la epilepsia. En relación con las métricas previamente definidas, la sensibilidad presentó consistentemente un valor de cero en todas las iteraciones realizadas. A pesar de que la especificidad alcanzó regularmente el 100 % y la precisión/exactitud llegó al 81 %, la persistente sensibilidad en cero para cada iteración impactó negativamente en los resultados de clasificación. Los detalles de estas iteraciones se presentan en la Tabla 12 correspondiente al primer entrenamiento de la red neuronal.

Lo anterior lleva a realizar un nuevo procedimiento contemplado en el cumplimiento de los objetivos específicos basándose en la descomposición de las señales a través del EMD.

### 5.2. Descomposición de señales

La implementación de la Descomposición Empírica de Modos (EMD) en la base de datos proveniente de PhysioNet ha demostrado ser un enfoque altamente efectivo y fructífero en la consecución de los objetivos establecidos en este estudio. La aplicación de la EMD ha posibilitado la descomposición precisa y adaptativa de las señales fisiológicas, proporcionando así una herramienta robusta para el análisis de datos biomédicos. La principal ventaja derivada de esta descomposición es la obtención de las Funciones de Modo Intrínseco (IMFs), que representan componentes fundamentales de las señales y permiten una comprensión más profunda de su comportamiento subyacente.

Esta riqueza de información extraída mediante la EMD ha facilitado análisis detallados so-

Tabla 12: Resultados de entrenamiento de la red neuronal variando hiperparámetros

Numero de neuronas	Epochs	Batch size	Accuracy [%]	Sensitivity [%]	Specificity [%]
16	20	10	81	0	100
		20	81	0	100
		30	81	0	100
		40	81	0	100
		50	81	0	100
32	20	10	81	0	100
		20	81	0	100
		30	81	0	100
		40	81	0	100
		50	81	0	100
64	20	10	81	0	100
		20	81	0	100
		30	81	0	100
		40	81	0	100
		50	81	0	100
128	20	10	81	0	100
		20	81	0	100
		30	81	0	100
		40	81	0	100
		50	81	0	100
256	20	10	81	0	100
		20	81	0	100
		30	81	0	100
		40	81	0	100
		50	81	0	100

bre patrones temporales y características particulares presentes en las señales fisiológicas. Su capacidad adaptativa ha resultado invaluable para identificar y aislar patrones específicos de interés en los datos, mejorando significativamente la capacidad de discriminación y comprensión de fenómenos sutiles.

Asimismo, el procesamiento detallado de la base de datos PhysioNet ha conducido a la obtención de resultados óptimos que han contribuido a la generación de conocimiento en el ámbito de la investigación biomédica. La utilización de la EMD ha revelado información previamente no evidente en los datos brutos, desvelando relaciones y correlaciones sutiles que son esenciales para comprender fenómenos fisiológicos complejos.

En este contexto, la Descomposición Empírica de Modos se erige como una estrategia esencial para el análisis y la interpretación avanzada de datos biomédicos. Este enfoque ha proporcionado una perspectiva única, permitiendo una comprensión más completa y detallada de las complejidades inherentes a las señales fisiológicas contenidas en la base de datos PhysioNet. El presente estudio destaca la importancia de la EMD como una herramienta valiosa en la investigación biomédica, abriendo nuevas posibilidades para la identificación de patrones y fenómenos relevantes que, de otra manera, podrían pasar desapercibidos.

Por otro lado, la integración de la técnica Ensemble Empirical Mode Decomposition (EEMD) en este estudio surge de la necesidad de abordar de manera más eficiente las complejidades inherentes a las señales fisiológicas, que predominantemente exhiben comportamientos no lineales y no estacionarios. La EEMD se presenta como una herramienta especialmente pertinente en el análisis de este tipo de señales, ya que ofrece una adaptabilidad única para capturar estructuras intrínsecas y fenómenos dinámicos presentes en datos biomédicos.

Dada la naturaleza no lineal y no estacionaria de las señales fisiológicas, la EEMD, como extensión de la EMD, supera las limitaciones asociadas con señales no lineales. Esta metodología utiliza funciones de adaptación que contribuyen a superar problemas relacionados con el modo de mezcla inherente a la EMD, permitiendo así una descomposición precisa de señales no lineales y no estacionarias.

La importancia fundamental de la EEMD radica en su capacidad para adaptarse a la complejidad de las señales biomédicas, revelando estructuras intrínsecas que podrían pasar desapercibidas con técnicas más convencionales. En contextos biomédicos, donde la variabilidad y la no linealidad son características comunes, la aplicación de la EEMD se convierte en una elección esencial para desentrañar la información subyacente en los datos.

El análisis de señales no lineales es crucial en el estudio de sistemas biológicos y fisiológicos, ya que muchos de estos sistemas exhiben comportamientos no lineales en sus respuestas a diversos estímulos. La EEMD se presenta como una metodología valiosa que puede

capturar de manera efectiva las complejidades de estas respuestas, proporcionando una base sólida para la interpretación de fenómenos fisiológicos y la identificación de patrones significativos.

A través de la inclusión de la EEMD, se pretende no solo satisfacer los objetivos iniciales del trabajo de grado, sino también elevar la calidad y robustez del análisis, permitiendo una exploración más profunda de los fenómenos fisiológicos observados. Así, la decisión de adicionar la EEMD demuestra una respuesta proactiva a los desafíos inherentes a la investigación biomédica y subraya el compromiso con la obtención de resultados analíticos más precisos y significativos.

En resumen, la adición de la Descomposición Empírica de Modos Empíricos en este estudio se justifica por su capacidad única para abordar la no linealidad y la no estacionariedad presentes en señales fisiológicas. Esta técnica avanzada se revela como un recurso esencial para desvelar información más detallada y precisa, ampliando así la comprensión de fenómenos complejos en el ámbito biomédico y fortaleciendo la capacidad analítica de este estudio en particular.

### **5.3. Selección de variables fundamentales para la clasificación de señales**

A partir de la descomposición de señales a través de la EMD y la subsiguiente consecución de las Funciones de Modo Intrínseco (IMF) y Frecuencia Instantánea (IF) para cada una de las señales provenientes de la base de datos se determinó que el parámetro por el cual se seleccionarían las variables más significativas sería la frecuencia ya que por medio de este proceso se ofrece una representación detallada de la variabilidad en el dominio de las frecuencias presentes en las señales.

La elección de utilizar la frecuencia característica derivada de las funciones de modo intrínseco (IMFs) y las frecuencias instantáneas como métodos de selección de variables en este estudio se fundamenta en sus beneficios distintivos en comparación con otros enfoques convencionales, como la entropía y la energía.

En primer lugar, la relevancia clínica y biológica de las frecuencias características derivadas de las IMFs y las frecuencias instantáneas es innegable. Estas medidas capturan de manera más fiel los patrones y variaciones temporales presentes en las señales biológicas, lo que resulta especialmente crucial en el contexto de fenómenos complejos como las convulsiones epilépticas. La adaptabilidad a la variabilidad temporal es otro aspecto clave, ya que las frecuencias instantáneas permiten capturar cambios significativos en diferentes puntos temporales, siendo esenciales en entornos médicos donde las señales pueden experimentar fluctuaciones importantes.

La información multiescala proporcionada por la descomposición en funciones de modo intrínseco también es un factor determinante. Esta técnica permite representar las señales en diferentes escalas temporales a través de las IMFs, abordando así la complejidad intrínseca de las señales biológicas. Además, la capacidad de eliminar ruido no deseado es particularmente valiosa. La descomposición en IMFs facilita la identificación y aislamiento de componentes específicos de interés, mejorando la calidad de la señal al eliminar eficazmente el ruido no deseado y destacar las características relevantes para el diagnóstico de la epilepsia.

Otro aspecto destacado es la capacidad de las frecuencias instantáneas para capturar transitorios y cambios rápidos en las señales. Esta característica es esencial en el contexto de las convulsiones epilépticas, que a menudo se caracterizan por eventos transitorios y repentinos. En términos de interpretabilidad, las frecuencias características derivadas de las IMFs y las frecuencias instantáneas resultan más fácilmente comprensibles desde una perspectiva clínica, ya que reflejan de manera más directa las características fisiológicas y patrones biológicos presentes en las señales. En resumen, la elección de estas metodologías no solo mejora la robustez de la detección de convulsiones epilépticas, sino que también contribuye a una interpretación clínica más informada y precisa de las señales, facilitando así la toma de decisiones en el ámbito médico.

Finalmente, se escogió la frecuencia como el parámetro para seleccionar las variables de interés es por la Frecuencia Instantánea derivada de la descomposición. Su importan-

cia radica en su capacidad para resaltar las frecuencias características y transitorias que pueden estar presentes en la señal. En este caso en particular, donde se analiza la clasificación de señales epilépticas, la información contenida en las IFs permite una identificación visual mas precisa de las características frecuenciales específicas de las convulsiones. Esto, a su vez, mejora la capacidad de discernir entre eventos epilépticos y no epilépticos, contribuyendo significativamente a la efectividad del proceso de clasificación.

#### **5.4. Clasificación de señales**

Basándonos en los resultados presentados en la tabla 9, se evidencia una variación en las métricas propuestas. Es importante recordar que en la primera fase de entrenamiento, a pesar de las variaciones en los hiperparámetros, la red neuronal no lograba clasificar ninguna señal con convulsiones epilépticas. En este contexto, en las iteraciones posteriores, la red neuronal exhibe la capacidad de incrementar o reducir su tasa de aciertos, pero no sigue un patrón definido a medida que estos valores se modifican. Gráficamente se observa en las figuras 25, 26 y 27 donde claramente se nota la aleatoriedad de las métricas.

Se nota que los porcentajes de sensibilidad y especificidad fluctúan entre el 0% y el 100%, sin embargo, en ninguna de las iteraciones se encuentran valores cercanos entre estas métricas que confirmen una clasificación adecuada de las señales.

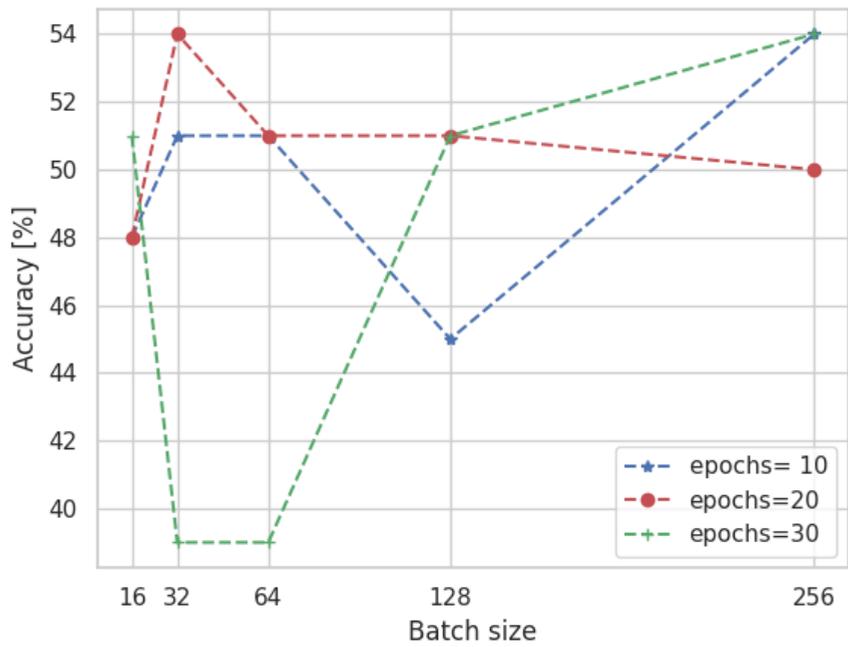


Figura 25: Valores de accuracy variando hiperparámetros

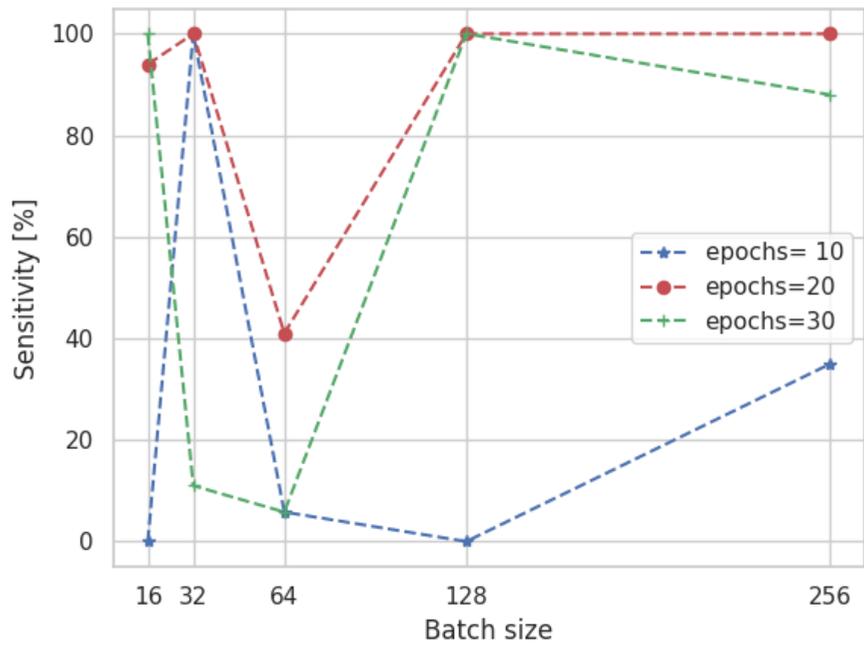


Figura 26: Valores de sensibilidad variando hiperparámetros

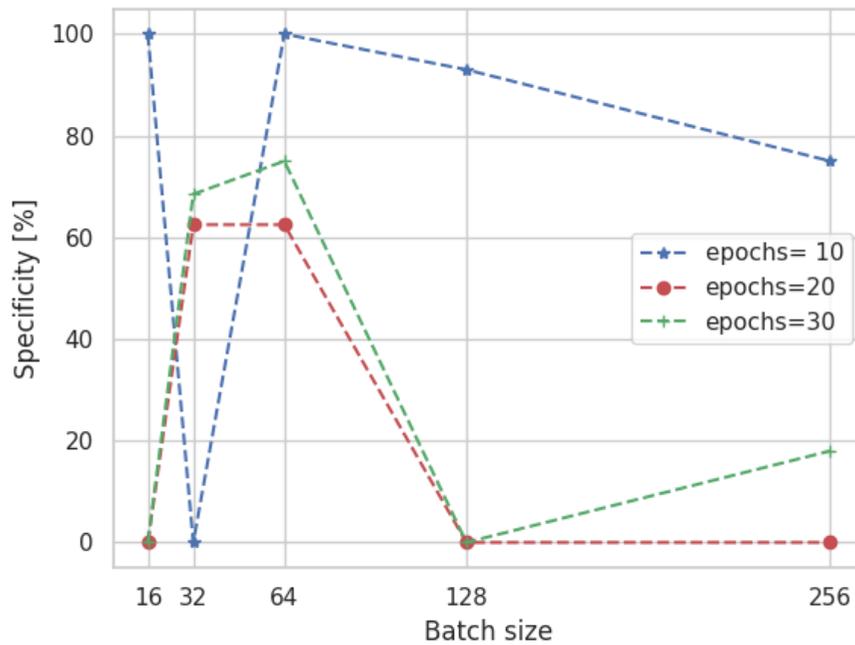


Figura 27: Valores de especificidad variando hiperparámetros

Al agregar una capa Bidireccional LSTM, la red neuronal obtiene la capacidad de capturar patrones en ambas dimensiones. Esto se logra al procesar la secuencia de entrada en direcciones ascendente y descendente, permitiendo que la red identifique patrones y dependencias temporales. Esta característica es especialmente valiosa en tareas donde la información relevante puede estar presente tanto en el pasado como en el futuro de un punto dado. Otra ventaja es que el modelo tiene más parámetros y, por lo tanto, una mayor capacidad de aprendizaje. Esta mayor complejidad puede ser beneficiosa para tareas más desafiantes o conjuntos de datos complejos.

La incorporación de una capa bidireccional LSTM es una estrategia común para mejorar el rendimiento de las redes neuronales en tareas que involucran secuencias temporales, permitiendo una mejor captura de patrones bidireccionales y una representación más rica del contexto.

Tras llevar a cabo múltiples iteraciones y analizar detenidamente los resultados presentados en la tabla 10, se evidencia que la introducción de la capa Bidireccional LSTM no

conlleva una mejora sustancial en las métricas de rendimiento de la red neuronal. En este contexto, el accuracy se mantiene en un rango cercano al 50 %, y se observa un fenómeno similar en los valores asociados a sensibilidad y especificidad. Estos hallazgos indican que la inclusión de la capa Bidireccional LSTM no aporta un impacto significativo en la capacidad de la red para discernir y clasificar de manera efectiva las señales estudiadas.. Las figuras 28, 29 y 30 muestran el comportamiento que tienen las métricas a medida que se varía el hiperparámetro epochs.

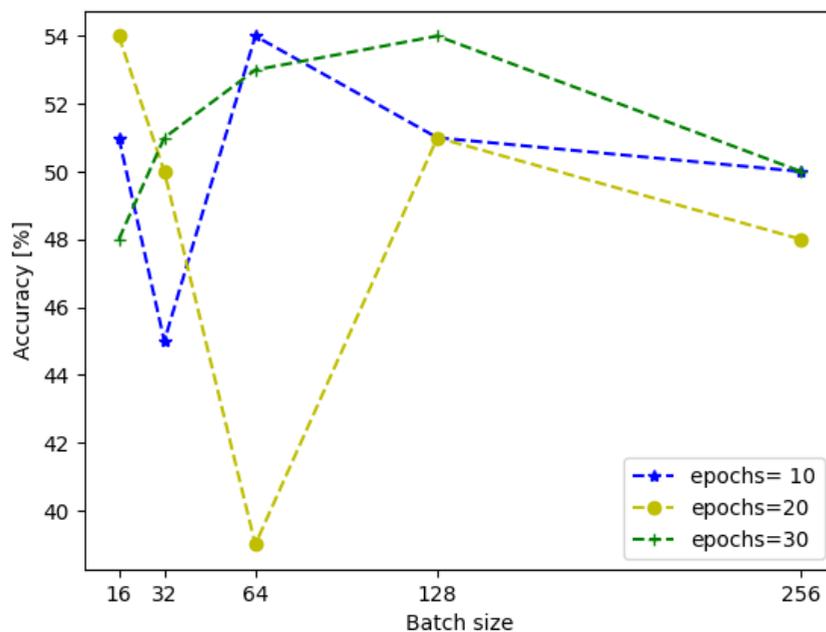


Figura 28: Accuracy con capa Bidireccional LSTM

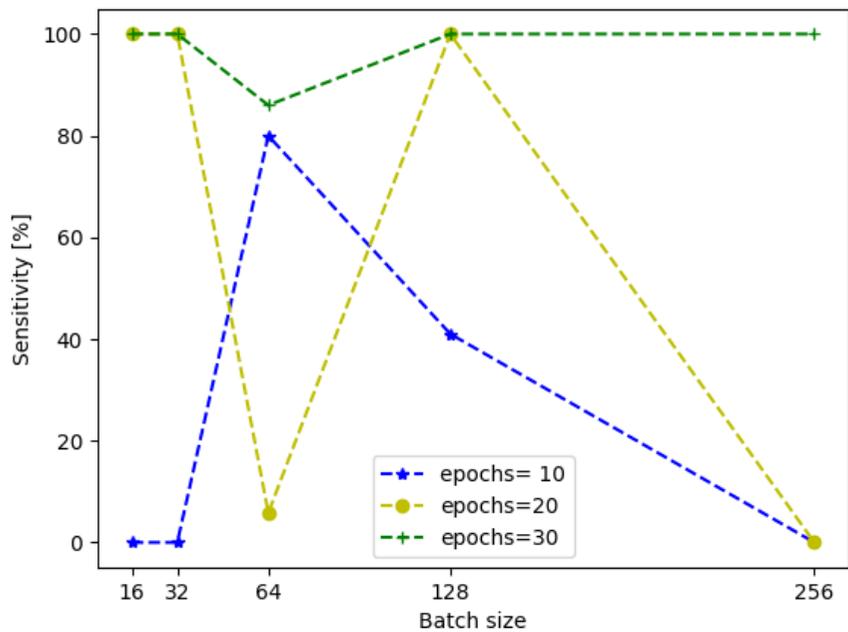


Figura 29: Sensibity con capa Bidirectional LSTM

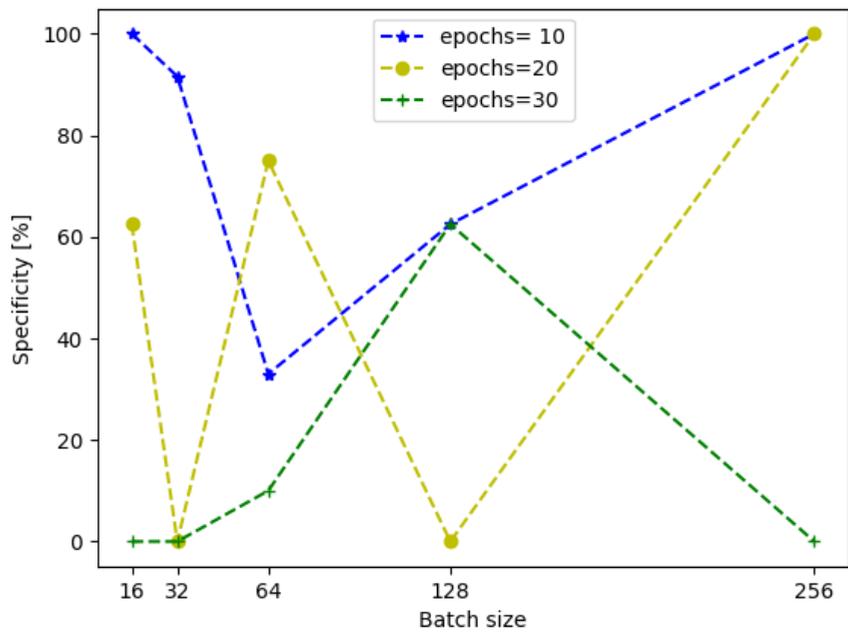


Figura 30: Specificity con capa Bidirectional LSTM

Los resultados previamente expuestos reflejan una similitud con lo observado al utilizar únicamente una capa en la red neuronal. A medida que se ajustan los hiperparámetros, los resultados muestran una variabilidad aleatoria que no se traduce en una mejora sustancial en el rendimiento del modelo.

Basándonos en el análisis realizado en el capítulo 4, donde se examina el desequilibrio de clases, se opta por investigar si este desbalance es el factor implícito que está contribuyendo a las dificultades en el aprendizaje de la red neuronal.

En primer lugar, la red está operando con dos categorías de muestras, evidenciándose un desequilibrio de clases. La clase mayoritaria corresponde a las señales no epilépticas, mientras que la clase minoritaria engloba las señales epilépticas. Con la última configuración de la red neuronal, se procesaron 357 muestras de la clase mayoritaria y 81 muestras de la clase minoritaria durante la lectura de datos.

Recordando que uno de los pasos en la configuración de la red neuronal consiste en llevar a cabo el muestreo de clases, en esta etapa se realizará específicamente un submuestreo, centrando el proceso en la clase minoritaria. No obstante, este enfoque presenta inconvenientes significativos debido al reducido número de muestras con las que finalmente queda la red neuronal.

Para abordar esta problemática, es crucial emplear el sobre-muestreo de las clases, reintegrándolo a la base de datos original que ha sido sometida previamente a un proceso de depuración y preprocesamiento de datos. Esta base de datos, después de dicho tratamiento, aún conserva 357 archivos correspondientes a la clase mayoritaria y 81 archivos de la clase minoritaria. El objetivo actual es lograr un equilibrio en la distribución de clases, permitiendo que la red neuronal pueda desempeñarse de manera efectiva. Por medio del código de programación donde realiza el sobremuestreo de las señales de la clase minoritaria se cumple con el objetivo de equilibrar las clases.

## 6. Conclusiones

En el presente caso de estudio, se propuso una metodología que integra un método de descomposición de señales no lineales y no estacionarias con un clasificador de señales para la detección de convulsiones epilépticas. Esta metodología consta de diversas etapas en las cuales se definen las características que debe poseer un método automatizado para la detección de convulsiones epilépticas. Estas características están detalladas en un diagrama de flujo, proporcionando una guía clara y precisa de los pasos a seguir para lograr una clasificación efectiva de las señales.

La EMD logra una descomposición eficaz de las señales presentes en la base de datos, identificando de manera precisa las frecuencias más relevantes para el caso de estudio. Por otro lado, al analizar las frecuencias instantáneas, se facilita la identificación visual de los momentos precisos en los que ocurre una convulsión, simplificando los procesos asociados. Este método de descomposición no solo destaca las frecuencias más relevantes, sino que también actúa como un filtro, permitiendo obtener señales más significativas para un caso de estudio específico.

Las redes neuronales artificiales es un método efectivo en esta investigación, pues su capacidad para aprender patrones complejos y no lineales permitió a través de la experimentación una interpretación mas precisa y automatizada de las señales. Su habilidad para aprender secuencialmente fue crucial para modelar patrones temporales, el cual es un aspecto fundamental en el diagnóstico de la epilepsia. Los resultados obtenidos respaldan la decisión de utilizar redes neuronales como herramienta fundamental en la clasificación de señales epilépticas, aportando avances significativos en el ámbito del diagnóstico y tratamiento de esta compleja condición médica.

La metodología propuesta en este trabajo de investigación, que integra un método de descomposición de señales con un clasificador, ha arrojado resultados destacados para el objetivo establecido. A pesar de la complejidad de la dinámica de las señales y los desafíos asociados con la clasificación a través de diversas arquitecturas de redes, junto con los costos computacionales involucrados, se ha logrado capturar la información prevista de

manera efectiva.

Aunque inicialmente la aplicación del método Ensemble Empirical Mode Decomposition (EEMD), derivado del EMD no estaba contemplada en los objetivos específicos de este trabajo de grado, su inclusión responde al reconocimiento de la complejidad intrínseca de las señales biomédicas y a la necesidad de emplear herramientas analíticas más avanzadas para descomponer de manera eficiente estas señales. La relevancia y capacidad demostrada por la EEMD para capturar fenómenos no lineales ha llevado a su incorporación como un componente adicional en el trabajo de grado.

La EEMD se presenta, por tanto, como una extensión valiosa a la metodología originalmente planteada, enriqueciendo el análisis y proporcionando una perspectiva más detallada de los patrones subyacentes en los datos biomédicos. Esta decisión estratégica refleja el compromiso con la mejora continua y la adaptación de la metodología ante la complejidad inherente de las señales analizadas.

## **6.1. Futuros trabajos**

En este trabajo de investigación, se ha conseguido con éxito la descomposición y clasificación de señales epilépticas. Se sugiere que, para futuras investigaciones, se aplique esta misma metodología a otros temas de investigación en diversas ramas de la ciencia.

Para mejorar los resultados, se sugiere ampliar este trabajo de investigación con el propósito de investigar si existe algún patrón distintivo que permita identificar los canales más relevantes para el diagnóstico de la epilepsia. Hasta el momento, el estado del arte presentado en este trabajo no ha posibilitado discernir en qué parte específica del cerebro o qué canales son los más determinantes para un diagnóstico preciso de la epilepsia. Esta extensión podría proporcionar una comprensión más profunda y precisa de los factores que influyen en el diagnóstico epileptológico.

## 7. Bibliografia

### Referencias

- [1] M. Rashed-Al-Mahfuz, M. A. Moni, S. Uddin, S. A. Alyami, M. A. Summers, and V. Eapen, “A deep convolutional neural network method to detect seizures and characteristic frequencies using epileptic electroencephalogram (eeg) data,” *IEEE Journal of Translational Engineering in Health and Medicine*, vol. 9, pp. 1–12, 2021.
- [2] L. A. Moctezuma, “Towards universal eeg systems with minimum channel count based on machine learning and computational intelligence,” Ph.D. dissertation, Norwegian University of Science and Technology, The address of the publisher, 8 2021.
- [3] S. Roy, I. Kiral-Kornek, and S. Harrer, “Chrononet: a deep recurrent neural network for abnormal eeg identification,” in *Conference on Artificial Intelligence in Medicine in Europe*. Springer, 2019, pp. 47–56.
- [4] A. Shoeibi, N. Ghassemi, R. Alizadehsani, M. Rouhani, H. Hosseini-Nejad, A. Khosravi, M. Panahiazar, and S. Nahavandi, “A comprehensive comparison of handcrafted features and convolutional autoencoders for epileptic seizures detection in eeg signals,” *Expert Systems with Applications*, vol. 163, p. 113788, 2021.
- [5] H. Berger, “Das elektrenkephalogramm des menschen,” *Naturwissenschaften*, vol. 23, no. 8, pp. 121–124, 1935.
- [6] H. Bhardwaj, A. Sakalle, A. Bhardwaj, and A. Tiwari, “Classification of electroencephalogram signal for the detection of epilepsy using innovative genetic programming,” *Expert Systems*, vol. 36, no. 1, p. e12338, 2019.
- [7] U. R. Acharya, S. L. Oh, Y. Hagiwara, J. H. Tan, and H. Adeli, “Deep convolutional neural network for the automated detection and diagnosis of seizure using eeg signals,” *Computers in biology and medicine*, vol. 100, pp. 270–278, 2018.

- [8] C. M. Michel and M. M. Murray, “Towards the utilization of eeg as a brain imaging tool,” *Neuroimage*, vol. 61, no. 2, pp. 371–385, 2012.
- [9] U. R. Acharya, Y. Hagiwara, S. N. Deshpande, S. Suren, J. E. W. Koh, S. L. Oh, N. Arunkumar, E. J. Ciaccio, and C. M. Lim, “Characterization of focal eeg signals: A review,” *Future Generation Computer Systems*, vol. 91, pp. 290–299, 2019. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0167739X18318818>
- [10] R. Ildar, “Progress in neural networks for eeg signal recognition in 2021,” *arXiv preprint arXiv:2103.15755*, 2021.
- [11] C. Gómez, P. Arbeláez, M. Navarrete, C. Alvarado-Rojas, M. Le Van Quyen, and M. Valderrama, “Automatic seizure detection based on imaged-eeg signals through fully convolutional networks,” *Scientific reports*, vol. 10, no. 1, pp. 1–13, 2020.
- [12] A. M. Abdelhameed, H. G. Daoud, and M. Bayoumi, “Deep convolutional bidirectional lstm recurrent neural network for epileptic seizure detection,” in *2018 16th IEEE International New Circuits and Systems Conference (NEWCAS)*. IEEE, 2018, pp. 139–143.
- [13] S. Li, W. Zhou, Q. Yuan, S. Geng, and D. Cai, “Feature extraction and recognition of ictal eeg using emd and svm,” *Computers in biology and medicine*, vol. 43, no. 7, pp. 807–816, 2013.
- [14] S.-F. Liang, H.-C. Wang, and W.-L. Chang, “Combination of eeg complexity and spectral analysis for epilepsy diagnosis and seizure detection,” *EURASIP journal on advances in signal processing*, vol. 2010, pp. 1–15, 2010.
- [15] J. P. Vergara Aguilar, D. Nariño González, U. E. Gómez Calzada, B. Gómez Arias, P. Martínez Micolta, D. Rosselli, C. Pantoja *et al.*, “Reunión de expertos en epilepsia,” *Acta Neurológica Colombiana*, vol. 35, no. 2, pp. 89–98, 2019.
- [16] L. Vidyaratne, A. Glandon, M. Alam, and K. M. Iftekharuddin, “Deep recurrent neural network for seizure detection,” in *2016 International Joint Conference on*

*Neural Networks (IJCNN)*. IEEE, 2016, pp. 1202–1207.

- [17] E. C. Dominguez, M. Subathra, N. Sairamya, and S. T. George, “Detection of focal epilepsy in brain maps through a novel pattern recognition technique,” *Neural Computing and Applications*, vol. 32, no. 14, pp. 10 143–10 157, 2020.
- [18] J. Engel Jr, “Evolution of concepts in epilepsy surgery,” *Epileptic Disorders*, vol. 21, no. 5, pp. 391–409, 2019.
- [19] A. R. Hassan, S. Siuly, and Y. Zhang, “Epileptic seizure detection in eeg signals using tunable-q factor wavelet transform and bootstrap aggregating,” *Computer methods and programs in biomedicine*, vol. 137, pp. 247–259, 2016.
- [20] S. Kulaseharan, A. Aminpour, M. Ebrahimi, and E. Widjaja, “Identifying lesions in paediatric epilepsy using morphometric and textural analysis of magnetic resonance images,” *NeuroImage: Clinical*, vol. 21, p. 101663, 2019.
- [21] G. Zazzaro, S. Cuomo, A. Martone, R. V. Montaquila, G. Toraldo, and L. Pavone, “Eeg signal analysis for epileptic seizures detection by applying data mining techniques,” *Internet of Things*, p. 100048, 2019.
- [22] N. van Klink, A. Mooij, G. Huiskamp, C. Ferrier, K. Braun, A. Hillebrand, and M. Zijlmans, “Simultaneous meg and eeg to detect ripples in people with focal epilepsy,” *Clinical Neurophysiology*, vol. 130, no. 7, pp. 1175–1183, 2019.
- [23] A. T. Tzallas, M. G. Tsipouras, D. G. Tsalikakis, E. C. Karvounis, L. Astrakas, S. Konitsiotis, and M. Tzaphlidou, “Automated epileptic seizure detection methods: a review study,” *Epilepsy-histological, electroencephalographic and psychological aspects*, pp. 75–98, 2012.
- [24] O. Faust, U. R. Acharya, H. Adeli, and A. Adeli, “Wavelet-based eeg processing for computer-aided seizure detection and epilepsy diagnosis,” *Seizure*, vol. 26, pp. 56–64, 2015.

- [25] S. Benbadis, “The differential diagnosis of epilepsy: a critical review,” *Epilepsy & Behavior*, vol. 15, no. 1, pp. 15–21, 2009.
- [26] P. A. Muñoz-Gutiérrez, E. Giraldo, M. Bueno-López, and M. Molinas, “Localization of active brain sources from eeg signals using empirical mode decomposition: A comparative study,” *Frontiers in Integrative Neuroscience*, vol. 12, p. 55, 2018. [Online]. Available: <https://www.frontiersin.org/article/10.3389/fnint.2018.00055>
- [27] M. Bueno-López, P. Muñoz-Gutiérrez, E. Giraldo, and M. Molinas, “Electroencephalographic source localization based on enhanced empirical mode decomposition,” *IAENG International Journal of Computer Science*, vol. 46, pp. 1–9, 2019.
- [28] M. Tudor, L. Tudor, and K. I. Tudor, “Hans berger (1873-1941)–the history of electroencephalography,” *Acta medica Croatica: casopis Hrvatske akademije medicinskih znanosti*, vol. 59, no. 4, pp. 307–313, 2005.
- [29] Y. Paul, “Various epileptic seizure detection techniques using biomedical signals: a review,” *Brain informatics*, vol. 5, no. 2, pp. 1–19, 2018.
- [30] R. G. Andrzejak, K. Schindler, and C. Rummel, “Nonrandomness, nonlinear dependence, and nonstationarity of electroencephalographic recordings from epilepsy patients,” *Physical Review E*, vol. 86, no. 4, p. 046206, 2012.
- [31] P. A. Muñoz, E. Giraldo, M. Bueno-López, and M. Molinas, “Automatic selection of frequency bands for electroencephalographic source localization,” in *2019 9th International IEEE/EMBS Conference on Neural Engineering (NER)*, 2019, pp. 1179–1182.
- [32] M. Bueno-López, E. Giraldo, and M. Molinas, “Analysis of neural activity from EEG data based on emd frequency bands,” in *2017 24th IEEE International Conference on Electronics, Circuits and Systems (ICECS)*, 2017, pp. 401–405.
- [33] O. K. Cura, S. K. Atli, H. S. Türe, and A. Akan, “Epileptic seizure classifications using empirical mode decomposition and its derivative,” *Biomedical engineering online*, vol. 19, no. 1, pp. 1–22, 2020.

- [34] M. K. Siddiqui, R. Morales-Menendez, X. Huang, and N. Hussain, “A review of epileptic seizure detection using machine learning classifiers,” *Brain informatics*, vol. 7, pp. 1–18, 2020.
- [35] R. Hussein, H. Palangi, R. Ward, and Z. J. Wang, “Epileptic seizure detection: A deep learning approach,” *arXiv preprint arXiv:1803.09848*, 2018.
- [36] A. Soler, P. Muñoz-Gutiérrez, M. Bueno-López, E. Giraldo, and M. Molinas, “Low-density eeg for neural activity reconstruction using multivariate empirical mode decomposition,” *Frontiers in neuroscience*, vol. 14, no. 175, pp. 1–17, 2020.
- [37] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [38] M. Rodriguez, J. Sotomonto, J. Cifuentes, and M. Bueno-López, “A classification method for power-quality disturbances using Hilbert–Huang transform and LSTM recurrent neural networks,” *Journal of Electrical Engineering & Technology*, vol. 16, pp. 249–266, 2021.
- [39] N. Yalcin, G. Tezel, and C. Karakuzu, “Epilepsy diagnosis using artificial neural network learned by pso,” *Turkish Journal of Electrical Engineering & Computer Sciences*, vol. 23, no. 2, pp. 421–432, 2015.
- [40] O. Faust, Y. Hagiwara, T. J. Hong, O. S. Lih, and U. R. Acharya, “Deep learning for healthcare applications based on physiological signals: A review,” *Computer methods and programs in biomedicine*, vol. 161, pp. 1–13, 2018.
- [41] N. Ghassemi, A. Shoeibi, and M. Rouhani, “Deep neural network with generative adversarial networks pre-training for brain tumor classification based on mr images,” *Biomedical Signal Processing and Control*, vol. 57, p. 101678, 2020.
- [42] V. Srinivasan, C. Eswaran, , and N. Sriraam, “Artificial neural network based epileptic detection using time-domain and frequency-domain features,” *Journal of Medical Systems*, vol. 29, no. 6, pp. 647–660, 2005.

- [43] P. R. Carney, S. Myers, and J. D. Geyer, "Seizure prediction: methods," *Epilepsy & behavior*, vol. 22, pp. S94–S101, 2011.
- [44] M. Agrawal and A. Biswas, "Molecular diagnostics of neurodegenerative disorders," *Frontiers in molecular biosciences*, vol. 2, p. 54, 2015.
- [45] M. G. Erkkinen, M.-O. Kim, and M. D. Geschwind, "Clinical neurology and epidemiology of the major neurodegenerative diseases," *Cold Spring Harbor perspectives in biology*, vol. 10, no. 4, p. a033118, 2018.
- [46] W. Mardini, M. M. B. Yassein, R. Al-Rawashdeh, S. Aljawarneh, Y. Khamayseh, and O. Meqdadi, "Enhanced detection of epileptic seizure using eeg signals in combination with machine learning classifiers," *IEEE Access*, vol. 8, pp. 24 046–24 055, 2020.
- [47] R. Vashistha, D. Yadav, D. Chhabra, and P. Shukla, "Artificial intelligence integration for neurodegenerative disorders," in *Leveraging Biomedical and Healthcare Data*. Elsevier, 2019, pp. 77–89.
- [48] J.-J. Wang, W.-Y. Lin, C.-S. Lu, Y.-H. Weng, S.-H. Ng, C.-H. Wang, H.-L. Liu, R.-H. Hsieh, Y.-L. Wan, and Y.-Y. Wai, "Parkinson disease: diagnostic utility of diffusion kurtosis imaging," *Radiology*, vol. 261, no. 1, pp. 210–217, 2011.
- [49] J.-H. Kang, Y. G. Chung, and S.-P. Kim, "An efficient detection of epileptic seizure by differentiation and spectral analysis of electroencephalograms," *Computers in biology and medicine*, vol. 66, pp. 352–356, 2015.
- [50] R. M. Mehmood and H. J. Lee, "Eeg based emotion recognition from human brain using hjorth parameters and svm," *International Journal of Bio-Science and Bio-Technology*, vol. 7, no. 3, pp. 23–32, 2015.
- [51] N. Ahammad, T. Fathima, and P. Joseph, "Detection of epileptic seizure event and onset using eeg," *BioMed research international*, vol. 2014, 2014.

- [52] S. Xie and S. Krishnan, “Wavelet-based sparse functional linear model with applications to eegs seizure detection and epilepsy diagnosis,” *Medical & biological engineering & computing*, vol. 51, no. 1, pp. 49–60, 2013.
- [53] V. K. Mehla, A. Singhal, P. Singh, and R. B. Pachori, “An efficient method for identification of epileptic seizures from eeg signals using fourier analysis,” *Physical and Engineering Sciences in Medicine*, pp. 1–14, 2021.
- [54] Y. Du, J. Jin, Y. Liu, and Q. Wang, “Classification of seizure eegs based on short-time fourier transform and hidden markov model,” in *2020 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC)*. IEEE, 2020, pp. 875–880.
- [55] B. Zhang, W. Wang, Y. Xiao, S. Xiao, S. Chen, S. Chen, G. Xu, and W. Che, “Cross-subject seizure detection in eegs using deep transfer learning,” *Computational and Mathematical Methods in Medicine*, vol. 2020, 2020.
- [56] Z. Gao, W. Dang, X. Wang, X. Hong, L. Hou, K. Ma, and M. Perc, “Complex networks and deep learning for eeg signal analysis,” *Cognitive Neurodynamics*, pp. 1–20, 2020.
- [57] E. Alickovic, J. Kevric, and A. Subasi, “Performance evaluation of empirical mode decomposition, discrete wavelet transform, and wavelet packed decomposition for automated epileptic seizure detection and prediction,” *Biomedical signal processing and control*, vol. 39, pp. 94–102, 2018.
- [58] M. Sharma, R. B. Pachori, and U. R. Acharya, “A new approach to characterize epileptic seizures using analytic time-frequency flexible wavelet transform and fractal dimension,” *Pattern Recognition Letters*, vol. 94, pp. 172–179, 2017.
- [59] R. B. Pachori and S. Patidar, “Epileptic seizure classification in eeg signals using second-order difference plot of intrinsic mode functions,” *Computer methods and programs in biomedicine*, vol. 113, no. 2, pp. 494–502, 2014.

- [60] R. Sharma and R. B. Pachori, “Classification of epileptic seizures in eeg signals based on phase space representation of intrinsic mode functions,” *Expert Systems with Applications*, vol. 42, no. 3, pp. 1106–1117, 2015.
- [61] Z. Zhang, Z. Li, T. Ma, and J. Zhao, “Eeg signal classification method based on improved empirical mode decomposition and svm,” in *Journal of Physics: Conference Series*, vol. 1846, no. 1. IOP Publishing, 2021, p. 012054.
- [62] S. S. Alam and M. I. H. Bhuiyan, “Detection of seizure and epilepsy using higher order statistics in the emd domain,” *IEEE journal of biomedical and health informatics*, vol. 17, no. 2, pp. 312–318, 2013.
- [63] V. Gupta, A. Bhattacharyya, and R. B. Pachori, “Classification of seizure and non-seizure eeg signals based on emd-tqwt method,” in *2017 22nd International Conference on Digital Signal Processing (DSP)*. IEEE, 2017, pp. 1–5.
- [64] R. J. Martis, U. R. Acharya, J. H. Tan, A. Petznick, R. Yanti, C. K. Chua, E. K. Ng, and L. Tong, “Application of empirical mode decomposition (emd) for automated detection of epilepsy using eeg signals,” *International journal of neural systems*, vol. 22, no. 06, p. 1250027, 2012.
- [65] M. Zhou, C. Tian, R. Cao, B. Wang, Y. Niu, T. Hu, H. Guo, and J. Xiang, “Epileptic seizure detection based on eeg signals and cnn,” *Frontiers in neuroinformatics*, vol. 12, p. 95, 2018.
- [66] R. San-Segundo, M. Gil-Martín, L. F. D’Haro-Enriquez, and J. M. Pardo, “Classification of epileptic eeg recordings using signal transforms and convolutional neural networks,” *Computers in biology and medicine*, vol. 109, pp. 148–158, 2019.
- [67] C. Li, W. Zhou, G. Liu, Y. Zhang, M. Geng, Z. Liu, S. Wang, and W. Shang, “Seizure onset detection using empirical mode decomposition and common spatial pattern,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 29, pp. 458–467, 2021.

- [68] Y. Kumar, M. Dewal, and R. Anand, “Epileptic seizure detection using dwt based fuzzy approximate entropy and support vector machine,” *Neurocomputing*, vol. 133, pp. 271–279, 2014.
- [69] A. Bhattacharyya, R. B. Pachori, A. Upadhyay, and U. R. Acharya, “Tunable-q wavelet transform based multiscale entropy measure for automated classification of epileptic eeg signals,” *Applied Sciences*, vol. 7, no. 4, p. 385, 2017.
- [70] V. R. Carvalho, M. F. Moraes, A. P. Braga, and E. M. Mendes, “Evaluating five different adaptive decomposition methods for eeg signal seizure detection and classification,” *Biomedical Signal Processing and Control*, vol. 62, p. 102073, 2020.
- [71] M. Zabihi, S. Kiranyaz, A. B. Rad, A. K. Katsaggelos, M. Gabbouj, and T. Ince, “Analysis of high-dimensional phase space via poincaré section for patient-specific seizure detection,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 24, no. 3, pp. 386–398, 2015.
- [72] R. G. Thangarajoo, M. B. I. Reaz, G. Srivastava, F. Haque, S. H. M. Ali, A. A. A. Bakar, and M. A. S. Bhuiyan, “Machine learning-based epileptic seizure detection methods using wavelet and emd-based decomposition techniques: A review,” *Sensors*, vol. 21, no. 24, p. 8485, 2021.
- [73] D. Jacobs, T. Hilton, M. Del Campo, P. L. Carlen, and B. L. Bardakjian, “Classification of pre-clinical seizure states using scalp eeg cross-frequency coupling features,” *IEEE Transactions on Biomedical Engineering*, vol. 65, no. 11, pp. 2440–2449, 2018.
- [74] S. Patidar and T. Panigrahi, “Detection of epileptic seizure using kraskov entropy applied on tunable-q wavelet transform of eeg signals,” *Biomedical Signal Processing and Control*, vol. 34, pp. 74–80, 2017.
- [75] H. Khan, L. Marcuse, M. Fields, K. Swann, and B. Yener, “Focal onset seizure prediction using convolutional networks,” *IEEE Transactions on Biomedical Engineering*, vol. 65, no. 9, pp. 2109–2118, 2017.

- [76] M. Kaleem, A. Guergachi, and S. Krishnan, “Patient-specific seizure detection in long-term eeg using wavelet decomposition,” *Biomedical Signal Processing and Control*, vol. 46, pp. 157–165, 2018.
- [77] S. Ibrahim, R. Djemal, and A. Alsuwailem, “Electroencephalography (eeg) signal processing for epilepsy and autism spectrum disorder diagnosis,” *Biocybernetics and Biomedical Engineering*, vol. 38, no. 1, pp. 16–26, 2018.
- [78] K. M. Tsiouris, S. Markoula, S. Konitsiotis, D. D. Koutsouris, and D. I. Fotiadis, “A robust unsupervised epileptic seizure detection methodology to accelerate large eeg database evaluation,” *Biomedical Signal Processing and Control*, vol. 40, pp. 275–285, 2018.
- [79] M. Z. Parvez and M. Paul, “Seizure prediction using undulated global and local features,” *IEEE Transactions on Biomedical Engineering*, vol. 64, no. 1, pp. 208–217, 2016.
- [80] Q. Yuan, W. Zhou, L. Zhang, F. Zhang, F. Xu, Y. Leng, D. Wei, and M. Chen, “Epileptic seizure detection based on imbalanced classification and wavelet packet transform,” *Seizure*, vol. 50, pp. 99–108, 2017.
- [81] O. Fasil and R. Rajesh, “Time-domain exponential energy for epileptic eeg signal classification,” *Neuroscience letters*, vol. 694, pp. 1–8, 2019.
- [82] A. B. Das and M. I. H. Bhuiyan, “Discrimination and classification of focal and non-focal eeg signals using entropy-based features in the emd-dwt domain,” *biomedical signal processing and control*, vol. 29, pp. 11–21, 2016.
- [83] A. Zahra, N. Kanwal, N. ur Rehman, S. Ehsan, and K. D. McDonald-Maier, “Seizure detection from eeg signals using multivariate empirical mode decomposition,” *Computers in biology and medicine*, vol. 88, pp. 132–141, 2017.
- [84] S. Raghu, N. Sriraam, Y. Temel, S. V. Rao, A. S. Hegde, and P. L. Kubben, “Performance evaluation of dwt based sigmoid entropy in time and frequency domains for

- automated detection of epileptic seizures using svm classifier,” *Computers in biology and medicine*, vol. 110, pp. 127–143, 2019.
- [85] M. K. Bandil and A. Wadhvani, “Multi-resolution eeg and eeg sub-band features optimization for epileptic classification using hybrid evolutionary computing technique,” *Procedia Computer Science*, vol. 152, pp. 243–251, 2019.
- [86] Q. Yuan, W. Zhou, S. Li, and D. Cai, “Epileptic eeg classification based on extreme learning machine and nonlinear features,” *Epilepsy research*, vol. 96, no. 1-2, pp. 29–38, 2011.
- [87] O. Karabiber Cura, S. Kocaaslan Atli, H. S. Türe, and A. Akan, “Epileptic seizure classifications using empirical mode decomposition and its derivative,” *Biomedical engineering online*, vol. 19, no. 1, pp. 1–22, 2020.
- [88] Y. Zheng, G. Wang, K. Li, G. Bao, and J. Wang, “Epileptic seizure prediction using phase synchronization based on bivariate empirical mode decomposition,” *Clinical Neurophysiology*, vol. 125, no. 6, pp. 1104–1111, 2014.
- [89] R. Djemili, H. Bourouba, and M. A. Korba, “Application of empirical mode decomposition and artificial neural network for the classification of normal and epileptic eeg signals,” *Biocybernetics and Biomedical Engineering*, vol. 36, no. 1, pp. 285–291, 2016.
- [90] R. J. Oweis and E. W. Abdulhay, “Seizure classification in eeg signals utilizing hilbert-huang transform,” *Biomedical engineering online*, vol. 10, no. 1, pp. 1–15, 2011.
- [91] C. Gasquet and P. Witomski, *Fourier analysis and applications: filtering, numerical computation, wavelets*. Springer Science & Business Media, 2013, vol. 30.
- [92] F. Series, “Fourier series & fourier transforms,” *BioMedical Engineering OnLine*, 2003.

- [93] A. T. Tzallas, M. G. Tsipouras, and D. I. Fotiadis, “Epileptic seizure detection in eegs using time–frequency analysis,” *IEEE transactions on information technology in biomedicine*, vol. 13, no. 5, pp. 703–710, 2009.
- [94] A. Gramfort, M. Luessi, E. Larson, D. A. Engemann, D. Strohmeier, C. Brodbeck, L. Parkkonen, and M. S. Hämäläinen, “Mne software for processing meg and eeg data,” *Neuroimage*, vol. 86, pp. 446–460, 2014.
- [95] M. E. Valentinuzzi, “Bioelectrical signal processing in cardiac and neurological applications and electromyography: physiology, engineering, and noninvasive applications,” *BioMedical Engineering OnLine*, vol. 6, p. 27, 2007.
- [96] R. H. Chowdhury, M. B. Reaz, M. A. B. M. Ali, A. A. Bakar, K. Chellappan, and T. G. Chang, “Surface electromyography signal processing and classification techniques,” *Sensors*, vol. 13, no. 9, pp. 12 431–12 466, 2013.
- [97] D. Benitez, P. Gaydecki, A. Zaidi, and A. Fitzpatrick, “The use of the hilbert transform in ecg signal analysis,” *Computers in biology and medicine*, vol. 31, no. 5, pp. 399–406, 2001.
- [98] C. Saritha, V. Sukanya, and Y. N. Murthy, “Ecg signal analysis using wavelet transforms,” *Bulg. J. Phys*, vol. 35, no. 1, pp. 68–77, 2008.
- [99] S. Salih, *Fourier Transform: Applications*. BoD–Books on Demand, 2012.
- [100] J. Almira, “Matemáticas para recuperación de señales,” *SC: Grupo Editorial Universitario*, 2005.
- [101] E. Cano, R. Salcedo, and G. Soto, “Análisis de principios y aplicaciones de la transformada wavelet,” *Universidad Nacional de Catamarca*, 2010.
- [102] B. P. Lathi and R. A. Green, *Signal processing and linear systems*. Oxford University Press New York, 1998.
- [103] P. S. Addison, *The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance*. CRC press, 2017.

- [104] L. Debnath and F. A. Shah, *Wavelet transforms and their applications*. Springer, 2002.
- [105] M. Bueno-López, M. Molinas, and G. Kulia, “Understanding instantaneous frequency detection: A discussion of hilbert-huang transform versus wavelet transform,” in *International Work-Conference on Time Series Analysis-ITISE*, vol. 1. University of Granada Granada, 2017, pp. 474–486.
- [106] P. Yadav, “A brief description of wavelet and wavelet transforms and their applications,” *International Journal of Statistics and Applied Mathematics*, vol. 3, no. 1, pp. 266–271, 2018.
- [107] D. Chen, S. Wan, and F. S. Bao, “Epileptic focus localization using discrete wavelet transform based on interictal intracranial eeg,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 25, no. 5, pp. 413–425, 2016.
- [108] M. Colominas, G. Schlotthauer, P. Flandrin, and M. E. Torres, “Descomposición empírica en modos por conjuntos completa con ruido adaptativo y aplicaciones biomédicas,” in *XVIII Congreso Argentino de Bioingeniería y VII Jornadas de Ingeniería Clínica, Mar del Plata, Argentina*, 09 2011.
- [109] Y. Lei, J. Lin, Z. He, and M. J. Zuo, “A review on empirical mode decomposition in fault diagnosis of rotating machinery,” *Mechanical systems and signal processing*, vol. 35, no. 1-2, pp. 108–126, 2013.
- [110] M. Peel, G. Pegram, and T. McMahon, “Empirical mode decomposition: improvement and application,” in *Proc. Int. Congress Modelling Simulation*, vol. 1. Citeseer, 2007, pp. 2996–3002.
- [111] S.-c. WU, W.-w. ZHAO, and Y.-h. CHEN, “Application research of hilbert transform in reactive energy measurement [j],” *Electrical Measurement & Instrumentation*, vol. 6, 2009.
- [112] M. Klingspor, “Hilbert transform: Mathematical theory and applications to signal processing,” 2015.

- [113] H. Luo, X. Fang, and B. Ertas, “Hilbert transform and its engineering applications,” *AIAA journal*, vol. 47, no. 4, pp. 923–932, 2009.
- [114] N. E. Huang, *Hilbert-Huang transform and its applications*. World Scientific, 2014, vol. 16.
- [115] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N.-C. Yen, C. C. Tung, and H. H. Liu, “The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis,” *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, vol. 454, no. 1971, pp. 903–995, 1998.
- [116] O. Blog, “¿ qué es el machine learning?” <https://www.ovhcloud.com/es/public-cloud/machine-learning-definicion/>, 2021.
- [117] G. Hinton, L. Deng, D. Yu, G. E. Dahl, A.-r. Mohamed, N. Jaitly, A. Senior, V. Vanhoucke, P. Nguyen, T. N. Sainath *et al.*, “Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups,” *IEEE Signal processing magazine*, vol. 29, no. 6, pp. 82–97, 2012.
- [118] M. Murshed, C. Murphy, D. Hou, N. Khan, G. Ananthanarayanan, and F. Hussain, “Machine learning at the network edge: A survey,” *arXiv preprint arXiv:1908.00080*, 2019.
- [119] G. Ananthanarayanan, P. Bahl, P. Bodík, K. Chintalapudi, M. Philipose, L. Ravindranath, and S. Sinha, “Real-time video analytics: The killer app for edge computing,” *computer*, vol. 50, no. 10, pp. 58–67, 2017.
- [120] N. Jouppi, “Google supercharges machine learning tasks with tpu custom chip,” *Google Blog, May*, vol. 18, no. 1, 2016.
- [121] U. Drolia, K. Guo, and P. Narasimhan, “Precog: Prefetching for image recognition applications at the edge,” in *Proceedings of the Second ACM/IEEE Symposium on Edge Computing*, 2017, pp. 1–13.

- [122] P. Warden, “Speech commands: A dataset for limited-vocabulary speech recognition,” *arXiv preprint arXiv:1804.03209*, 2018.
- [123] R. R. Janghel, A. Shukla, R. Tiwari, and R. Kala, “Breast cancer diagnosis using artificial neural network models,” in *The 3rd International Conference on Information Sciences and Interaction Sciences*, 2010, pp. 89–94.
- [124] O. Abdeljaber, O. Avci, S. Kiranyaz, M. Gabbouj, and D. J. Inman, “Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks,” *Journal of Sound and Vibration*, vol. 388, pp. 154–170, 2017.
- [125] S. A. Osia, A. S. Shamsabadi, A. Taheri, H. R. Rabiee, and H. Haddadi, “Private and scalable personal data analytics using hybrid edge-to-cloud deep learning,” *Computer*, vol. 51, no. 5, pp. 42–49, 2018.
- [126] I. Corporation, “Deep learning,” <https://www.ibm.com/co-es/cloud/deep-learning>, 2021.
- [127] M. K. Leung, H. Y. Xiong, L. J. Lee, and B. J. Frey, “Deep learning of the tissue-regulated splicing code,” *Bioinformatics*, vol. 30, no. 12, pp. i121–i129, 2014.
- [128] T. N. Sainath, B. Kingsbury, A.-r. Mohamed, G. E. Dahl, G. Saon, H. Soltau, T. Beran, A. Y. Aravkin, and B. Ramabhadran, “Improvements to deep convolutional neural networks for lvcsr,” in *2013 IEEE workshop on automatic speech recognition and understanding*. IEEE, 2013, pp. 315–320.
- [129] I. Sutskever, O. Vinyals, and Q. V. Le, “Sequence to sequence learning with neural networks,” *Advances in neural information processing systems*, vol. 27, 2014.
- [130] P. Cunningham, M. Cord, and S. J. Delany, “Supervised learning,” in *Machine learning techniques for multimedia*. Springer, 2008, pp. 21–49.
- [131] O. I. Abiodun, A. Jantan, A. E. Omolara, K. V. Dada, N. A. Mohamed, and H. Arshad, “State-of-the-art in artificial neural network applications: A survey,” *Heliyon*, vol. 4, no. 11, p. e00938, 2018.

- [132] Z. Zhang, “Artificial neural network,” in *Multivariate time series analysis in climate and environmental research*. Springer, 2018, pp. 1–35.
- [133] S. Haykin, *Neural networks and learning machines, 3/E*. Pearson Education India, 2009.
- [134] D. Wang, H. He, and D. Liu, “Intelligent optimal control with critic learning for a nonlinear overhead crane system,” *IEEE Transactions on Industrial Informatics*, vol. 14, no. 7, pp. 2932–2940, 2017.
- [135] M. Shokri and K. Tavakoli, “A review on the artificial neural network approach to analysis and prediction of seismic damage in infrastructure,” *Int. J. Hydromechanics*, vol. 4, pp. 178–196, 2019.
- [136] A. Dineva, A. Mosavi, S. Faizollahzadeh Ardabili, I. Vajda, S. Shamshirband, T. Rabczuk, and K.-W. Chau, “Review of soft computing models in design and control of rotating electrical machines,” *Energies*, vol. 12, no. 6, p. 1049, 2019.
- [137] Y.-J. Cha, W. Choi, and O. Büyüköztürk, “Deep learning-based crack damage detection using convolutional neural networks,” *Computer-Aided Civil and Infrastructure Engineering*, vol. 32, no. 5, pp. 361–378, 2017.
- [138] K. Gopalakrishnan, H. Gholami, A. Vidyadharan, A. Choudhary, and A. Agrawal, “Crack damage detection in unmanned aerial vehicle images of civil infrastructure using pre-trained deep learning model,” *Int. J. Traffic Transp. Eng*, vol. 8, no. 1, pp. 1–14, 2018.
- [139] O. Avci, O. Abdeljaber, S. Kiranyaz, and D. Inman, “Convolutional neural networks for real-time and wireless damage detection,” in *Dynamics of Civil Structures, Volume 2*. Springer, 2020, pp. 129–136.
- [140] D. J. Matich, “Redes neuronales: Conceptos básicos y aplicaciones,” *Universidad Tecnológica Nacional, México*, vol. 41, pp. 12–16, 2001.

- [141] M. Sotaquirá, “Las funciones de activación?” <https://www.codificandobits.com/blog/funcion-de-activacion/>, 2018.
- [142] G. L. Goldberger AL, Amaral LAN, “Physiobank, physiokit, and physionet: Components of a new research resource for complex physiologic signals,” <https://archive.physionet.org/pn6/chbmit/>, 2000.
- [143] J. Malmivuo and R. Plonsey, *Bioelectromagnetism. 13. Electroencephalography*, 01 1995, pp. 247–264.
- [144] A. H. Shoeb and J. V. Guttag, “Application of machine learning to epileptic seizure detection,” in *ICML*, 2010.
- [145] C. I. Corporation, “El modelo de redes neuronales,” <https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-neural-model>, 2021.

## 8. Anexos

Toda la información complementaria que puede ser relevante para entender el contenido del presente trabajo de grado se encuentra alojado en el enlace:

[github.com/leodorado/about\\_master\\_degree](https://github.com/leodorado/about_master_degree) del repositorio de GitHub.