



UNIVERSIDAD TECNOLÓGICA METROPOLITANA
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE ELECTRICIDAD
ESCUELA DE ELECTRÓNICA

DETECCIÓN DE ATAQUES EPILÉPTICOS MEDIANTE ANÁLISIS DE SEÑALES DE ELECTROENCÉFALOGRAMA

TRABAJO DE TITULACIÓN PARA OPTAR AL TÍTULO DE INGENIERO
CIVIL ELECTRÓNICO

AUTOR:
SEBASTIÁN URBINA FREDES

PROFESOR GUÍA:
ALI DEHGHANFIROUZABADI

SANTIAGO - CHILE
2023

AUTORIZACIÓN PARA LA REPRODUCCIÓN DEL TRABAJO DE TITULACIÓN

1.- Identificación del trabajo de titulación

Nombre del alumno : Sebastián Antonio Urbina Fredes

Rut

Dirección

E-mail : sebastian.urbinaf@gmail.com

Teléfono

Título de la tesis : Detección de Ataques Epilépticos Mediante Análisis de
Señales de Electroencefalograma

Escuela : Escuela de Electrónica

Carrera o programa : Ingeniería Civil Electrónica

Título al que opta : Ingeniero Civil Electrónico

2.- Autorización de reproducción

Se autoriza la reproducción total o parcial de este trabajo de titulación, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica que acredita al trabajo y a su autor. Es decir, que la Universidad está autorizada para a conocer, reproducir y/o publicar el trabajo de titulación sin perjuicio del derecho de autor.

En consideración a lo anterior, se autoriza su reproducción de forma inmediata.

Fecha: _____ Firma: _____

Esta autorización se otorga en el marco de la ley N°17.336 sobre Propiedad Intelectual, con carácter gratuito y no exclusivo para la Institución.

NOTA OBTENIDA:

FIRMA Y TIMBRE AUTORIDAD
RESPONSABLE

DEDICATORIA

Dedico esta investigación a mi familia y a mis seres queridos quienes, aún en los momentos más difíciles, siempre estuvieron alentándome a continuar.

AGRADECIMIENTOS

Agradezco infinitamente a mi madre, Lorena, quien siempre me ha apoyado de manera incondicional, sobretodo a lo largo de mi proceso universitario; a Estrella, mi amada, quien me alentó con firmeza durante la elaboración de este informe; a mi hermano, Alonso, quien me acompañaba a altas horas de la noche, mientras realizaba los quehaceres académicos; a mi tío abuelo, Tito, quien a temprana edad me animó a despertar el interés por la electrónica; al profesor guía, Ali, quien despejó todas las dudas que brotaron en el transcurso de esta investigación; a mi querida familia; a todas las personas que creyeron en mí y, a la UTEM, alma mater e institución en la cual tuve el privilegio de adquirir valiosos conocimientos, los cuales me serán de gran utilidad por el resto de mi vida.

ÍNDICE DE CONTENIDOS

Contenido	Página
Índice de tablas	X
Índice de ilustraciones	XII
Resumen	XIII
Abstract	XIV
1. Introducción	1
1.1. Introducción al tema de tesis	1
1.2. Justificación	2
1.3. Procesamiento de señales	2
1.4. Objetivos	2
1.4.1. Objetivos específicos	3
1.5. Alcances del estudio	3
1.6. Organización del trabajo	3
2. Antecedentes	5
2.1. Ingeniería biomédica	5
2.1.1. Señales biomédicas	5
2.2. El sistema nervioso	6
2.2.1. El cerebro humano	7
2.2.2. Neuronas	9

Contenido	Página
2.2.2.1. Potencial de acción	9
2.3. El Electroencefalograma	10
2.3.1. Montajes EEG	11
2.3.2. Sistema 10-20	11
2.4. Señales EEG	12
2.4.1. Ritmos cerebrales	13
2.4.1.1. Ritmo Delta (δ)	13
2.4.1.2. Ritmo Theta (θ)	13
2.4.1.3. Ritmos Alpha (α) - Mu (μ)	14
2.4.1.4. Ritmo Beta (β)	14
2.4.1.5. Ritmo Gamma (γ)	15
2.4.2. Potenciales relacionados con eventos	15
2.4.3. Artefactos	16
2.5. Registros de EEG durante crisis epilépticas	16
2.6. Bases de datos de registros EEG utilizadas	17
2.6.1. A dataset of neonatal EEG recordings with seizure annotations.	18
2.6.2. CHB-MIT Scalp EEG Database.	18
2.7. Estado del arte	18
2.8. Conclusión del capítulo	22
3. Marco teórico	23
3.1. Metodología propuesta	23
3.2. Relación señal-ruido	24
3.2.1. Coeficiente de correlación muestral	25
3.2.2. Filtro Savitzky-Golay	25
3.3. Caracterización de señales	27
3.3.1. Análisis tiempo frecuencia	27
3.3.2. Transformada Discreta de Fourier	28
3.3.3. Transformada Wavelet	28

Contenido	Página
3.3.3.1. Transformada Wavelet Continua	29
3.3.3.2. Transformada Wavelet Discreta	29
3.3.3.3. Transformada Wavelet para señales EEG	31
3.3.4. Extracción de características estadísticas	32
3.4. Aprendizaje de máquina	32
3.4.1. Aprendizaje supervisado:	33
3.4.2. Aprendizaje profundo	33
3.4.3. Aprendizaje por Refuerzo	34
3.4.4. Selección del modelo a utilizar	34
3.4.5. Máquina de vectores de soporte	35
3.4.5.1. Caso separable linealmente	35
3.4.5.2. Caso cuasi-separable linealmente	40
3.4.5.3. Caso no separable linealmente	42
3.5. Procesamiento de señales EEG en MATLAB	44
3.6. Conclusión del capítulo	45
4. Experimentación y Resultados	46
4.1. Análisis de señales EEG	46
4.1.1. Revisión de bases de datos EEG en MATLAB	46
4.1.1.1. Base de datos UCIN Hospital Universitario de Helsinki	46
4.1.1.2. Base de datos Hospital de Niños de Boston CHB-MIT	48
4.1.2. Consideraciones previas a los experimentos	49
4.2. Preprocesamiento de la señal EEG	49
4.2.1. Adición de Ruido Gaussiano Blanco a señales	49
4.2.2. Elección de parámetros de filtro Savitzky-Golay	50
4.2.3. Aplicación de Filtrado Savitzky-Golay	53
4.3. Descomposición de la señal EEG	54
4.4. Extracción de características	56
4.5. Entrenamiento de SVM y Clasificación de características	57

Contenido	Página
4.6. Resultados y discusión	59
4.7. Conclusión del capítulo	64
5. Conclusiones de la investigación	65
Bibliografía	67
Siglas	73

ÍNDICE DE TABLAS

3.1. Sección de información general de cabecera de archivo EDF	45
3.2. Sección de información de señales de cabecera de archivo EDF	45
4.1. Comparación entre SNR de entrada y SNR de salida de filtros S-G. . .	51
4.2. Índice de correlación entre señal de prueba y señales de salida de filtros S-G.	51
4.3. Resultados de clasificación de conjunto de datos CHB-MIT.	60
4.4. Resultados de clasificación de conjunto de datos Hospital de Helsinki	62
4.5. Resultados de clasificación de conjunto de datos Hospital de Helsinki sin filtrar.	62

ÍNDICE DE ILUSTRACIONES

2.1. Vista superior y hemisferio izquierdo del cerebro humano.	8
2.2. Funciones asociadas a cada lóbulo cerebral.	8
2.3. Estructura general de una neurona.	9
2.4. Variación eléctrica del PA en el tiempo.	10
2.5. Sistema Internacional de ubicación de electrodos 10-20.	12
2.6. Ondas delta con banda de frecuencia de 0.5 a 4Hz.	13
2.7. Ondas theta con banda de frecuencia de 4 a 8Hz.	14
2.8. Ondas alpha con banda de frecuencia de 8 a 13Hz.	14
2.9. Ondas beta con banda de frecuencia de 13 a 30Hz.	15
2.10. Ondas gamma con banda de frecuencia de 30 a 100Hz.	15
2.11. Registro EEG de 5 minutos de duración con crisis epiléptica y sus fases.	17
2.12. Comparación PSD en [dB/Hz] de segmento EEG con y sin crisis epiléptica.	17
3.1. Diagrama de flujo de la metodología propuesta en la investigación. . .	24
3.2. Diagrama en bloques del banco de filtros de descomposición DWT. . .	31
3.3. Ejemplo de hiperplanos separadores para el caso separable linealmente.	36
3.4. Ejemplo de hiperplanos separadores para el caso cuasi-separable linealmente.	41
4.1. Registro EDF con fase ictal. Paciente 34, base de datos Hospital de Helsinki.	47
4.2. Gráfica de anotaciones paciente 34. Base de datos Hospital de Helsinki.	47

4.3. Registro EDF con fase ictal. Paciente 01, grabación 03, base de datos CHB-MIT.	48
4.4. Comparación de señal de prueba y señales con Ruido Gaussiano Blanco.	50
4.5. Comparación entre SNR de señales de salida de filtros SG y SNR de entrada.	52
4.6. Comparación entre espectrogramas de señal con ruido y señal con ruido filtrado	52
4.7. Comparación entre segmentos de señal de prueba y señal filtrada. . .	53
4.8. Descomposición de señal EEG en coeficientes de aproximación y detalle.	54
4.9. Gráfica de construcción de ritmos cerebrales <i>delta, theta, alpha, beta</i> y <i>gamma</i>	55
4.10. Gráfica de características del ritmo cerebral alpha	56
4.11. Gráfica de características del ritmo cerebral beta	57
4.12. Entrenamiento y clasificación de intervalo con crisis epiléptica.	58
4.13. Gráfica de precisión del clasificador para conjunto CHB-MIT	61
4.14. Gráfica de precisión del clasificador para conjunto Hospital de Helsinki	63

RESUMEN

En este trabajo de titulación se propone un método de diagnóstico automático de ataques de epilepsia analizando señales de electroencefalograma. Las técnicas implementadas se basaron en el prefiltrado de la señal de Electroencefalograma con el filtro Savitzky-Golay, la descomposición de la señal mediante Transformada Wavelet Discreta, la extracción de características y su posterior clasificación a través de Máquina de Vectores de Soporte. El pre-filtrado Savitzky-Golay mejoró la relación señal-ruido de las señales. Posteriormente, las señales fueron descompuestas utilizando Transformada Wavelet. Se emplearon diversos coeficientes wavelet para construir las representaciones en tiempo-frecuencia de los ritmos cerebrales espontáneos alpha, beta, gamma, theta y delta. Se extrajeron las características media, desviación estándar, asimetría, curtosis, entropía y energía de los ritmos alpha y beta en intervalos con ataque epiléptico y sin ataque. Se utilizaron los conjuntos de características en el entrenamiento de un clasificador binario Máquina de Vectores de Soporte con kernel lineal. Se clasificaron conjuntos de señales de prueba a través de los modelos SVM. El algoritmo realizó la detección de ataques de epilepsia alcanzando medias de precisión en las clasificaciones de entre 89.7 % y 93 %, demostrando la efectividad del método para realizar los diagnósticos.

Palabras clave – Electroencefalograma, Detección de ataques epilépticos, Filtro Savitzky-Golay, Transformada Wavelet Discreta, Máquina de Vectores de Soporte.

ABSTRACT

In this degree work, a method of automatic diagnosis of epileptic seizures is proposed by analyzing electroencephalogram (EEG) signals. The implemented techniques were based on the pre-filtering of the EEG signal with the Savitzky-Golay filter, the decomposition of the signal using Discrete Wavelet Transformation, the features extraction and its subsequent classification using the Support Vector Machine. Savitzky-Golay pre-filtering improved the signal-to-noise ratio of the signals. Subsequently, the signals were decomposed using Wavelet Transformation. Several wavelet coefficients were used to construct time-frequency representations of spontaneous alpha, beta, gamma, theta, and delta brain rhythms. The mean, standard deviation, skewness, kurtosis, entropy, and energy characteristics of the alpha and beta rhythms were extracted in intervals with epileptic seizure and without seizure. The feature sets were used in the training of a linear kernel Support Vector Machine binary classifier. Test signal sets were classified through the SVM models. The algorithm detected seizures, reaching average accuracy in the classifications of between 89.7% and 93%, demonstrating the effectiveness of the method for making diagnoses.

Keywords – Electroencephalogram, Seizure detection, Savitzky-Golay filter, Discrete Wavelet Transform, Support Vector Machine.

CAPÍTULO 1

Introducción

1.1. Introducción al tema de tesis

La Epilepsia es un trastorno que se caracteriza por la sincronización anormal de la actividad eléctrica en el cerebro. Los síntomas de una crisis epiléptica generalmente son: pérdida temporal de la atención, alucinaciones sensoriales y convulsiones en todo el cuerpo. La Liga Internacional Contra la Epilepsia (ILAE) define *crisis epiléptica* como la “aparición transitoria de signos y/o síntomas provocados por una actividad neuronal anómala excesiva o simultánea en el cerebro”. Por otra parte, ILAE define *epilepsia* como “un trastorno cerebral que se caracteriza por una predisposición continuada a la aparición de crisis epilépticas y por las consecuencias neurobiológicas, cognitivas, psicológicas y sociales de esta enfermedad” [1]. Según la Organización Mundial de la Salud (OMS) la epilepsia es “la enfermedad cerebral crónica más común y afecta a personas de todas las edades. En todo el mundo, unos 50 millones de personas padecen de este trastorno”. Además, “se estima que el 70 % de las personas con epilepsia podrían estar libres de crisis epilépticas si se les diagnostica y trata adecuadamente” [2]. La posibilidad de contribuir a mejorar la calidad de vida de quienes sufren de epilepsia identificando el trastorno de manera temprana incentiva a ingenieros e investigadores a analizar señales de Electroencefalograma (EEG) y a diseñar dispositivos que realicen la detección de ataques. En la bibliografía se registran algoritmos experimentales para detección de ataques epilépticos que han alcanzado niveles de precisión de 90 %, 95.6 %y 100 %, [3-5].

1.2. Justificación

La detección de crisis epilépticas en señales EEG habitualmente es realizada por neurofisiólogos capacitados para la inspección visual de los registros, método que sin embargo, resulta costoso, requiere de tiempo y puede producir diagnósticos erróneos debido a la complejidad de diferenciar las crisis de otros tipos de actividad cerebral [6]. Lo anterior conduce a la necesidad de crear dispositivos que realicen la detección automática de ataques epilépticos en señales EEG con alta precisión y velocidad. Una aplicación propuesta es la Interfaz Cerebro-Computadora (BCI) de alerta temprana de crisis epilépticas, que ofrece la posibilidad de resguardo previo del paciente frente a la ocurrencia de un ataque. Actualmente los esfuerzos se concentran en el diseño de algoritmos simples que tengan un bajo costo computacional y energético.

1.3. Procesamiento de señales

El análisis de señales EEG por medio de técnicas matemáticas y estadísticas de Procesamiento Digital de Señales (DSP) permite determinar características de la señal EEG que por inspección directa no es posible apreciar [7]. Las técnicas de extracción de características operan como análisis en función del tiempo, la frecuencia, tiempo y frecuencia combinados o como métodos estadísticos. La detección de ataques de epilepsia en señales EEG se basa en la clasificación de características utilizando técnicas de Aprendizaje de Máquinas tales como Aprendizaje Supervisado o Aprendizaje Profundo [8]. El algoritmo propuesto en este trabajo se constituye de una primera fase de prefiltrado y reducción de ruido de la señal EEG con filtro *Savitzky-Golay*, una segunda fase de descomposición tiempo-frecuencia de la señal con *Transformada Wavelet Discreta*, una tercera fase de extracción de características estadísticas y una última fase de clasificación de características con *Máquina de Vectores de Soporte*.

1.4. Objetivos

El objetivo principal de esta investigación es diseñar e implementar un algoritmo de procesamiento que realice la detección de convulsiones epilépticas en señales EEG.

1.4.1. Objetivos específicos

Los objetivos específicos de esta investigación son:

- a) Exponer los antecedentes que fundamentan el procedimiento seguido.
- b) Establecer un marco teórico sobre las técnicas DSP utilizadas.
- c) Implementar un algoritmo en el entorno de desarrollo MATLAB que realice la detección de ataques epilépticos en señales EEG.
- d) Lograr un alto nivel de precisión en el desempeño del algoritmo.

1.5. Alcances del estudio

El desarrollo de este estudio y sus resultados pretenden ser:

- Una contribución a los esfuerzos por realizar la detección precisa del trastorno de la epilepsia permitiendo mejorar la calidad de vida de quienes lo padecen.
- Un antecedente del uso de procesamiento digital de señales en la detección de ataques epilépticos en señales EEG.
- Un algoritmo útil para el análisis y clasificación de señales de EEG.
- Un marco teórico sobre algoritmos de caracterización de señales de EEG útil a otros estudios de esta naturaleza.

1.6. Organización del trabajo

La obra se encuentra dividida en 5 capítulos incluido el presente, denominados: Introducción, Antecedentes, Marco Teórico, Experimentación y Resultados, y Conclusión.

- En el **Capítulo 2**, se ofrece una revisión de los antecedentes que dan sustento a la investigación; las señales biomédicas, el sistema nervioso, el cerebro y las neuronas, el electroencefalógrafo, las señales EEG y sus características, las señales EEG asociadas a crisis epilépticas y los métodos disponibles en la bibliografía para realizar la detección de ataques epilépticos en señales EEG.

- En el **Capítulo 3** se define la metodología de la investigación y se describen analíticamente las técnicas matemáticas empleadas en el procesamiento de señales EEG para realizar la detección de crisis epilépticas. En particular, se da especial importancia al planteamiento y desarrollo matemático conducente a la obtención de las técnicas Filtro Savitzky-Golay, Transformada Wavelet Discreta y Máquina de Vectores de Soporte. Asimismo, se describen las características del formato de las señales EEG utilizadas y como operarlas en MATLAB.
- En el **Capítulo 4** se describe el procedimiento experimental llevado a cabo para el desarrollo del algoritmo de detección de convulsiones epilépticas en señales EEG. Se exponen las características principales de los archivos EDF de las bases de datos escogidas para este trabajo. Se muestra el análisis y procedimiento de ajuste de parámetros del filtro Savitzky-Golay para alcanzar los mejores desempeños. Se incluye el diagrama de la configuración del banco de filtros utilizado para la descomposición de las señales. Se presenta la metodología usada para la extracción de características. Luego, se detalla el procedimiento llevado a cabo para entrenar los modelos de decisión así como las clasificaciones realizadas por estos modelos sobre conjuntos de características construidos a partir de las señales EEG. Por último, se exponen los resultados de las clasificaciones en función de criterios de desempeño, así como las conclusiones derivadas del procedimiento.
- En el **Capítulo 5** se presentan las conclusiones de la investigación, algunas utilidades producto del desarrollo del algoritmo y nuevas maneras de abordar futuras investigaciones relacionadas.

CAPÍTULO 2

Antecedentes

2.1. Ingeniería biomédica

La ingeniería biomédica es una disciplina científica basada en el uso de técnicas de ingeniería para realizar la recolección, análisis y estudio de datos provenientes del cuerpo humano. Su objetivo principal es el diseño y construcción de equipos médicos, dispositivos de diagnóstico, prótesis, implantes o la gestión automatizada de recursos de hospitales. Actualmente, los avances de las ciencias computacionales y de datos han proporcionado sofisticadas técnicas para el procesamiento y clasificación de información de señales, permitiendo el desarrollo de dispositivos biomédicos avanzados, así como progresos en áreas de la electroencefalografía, electrocardiografía, imagenología, cirugía robótica y otras aplicaciones [9].

2.1.1. Señales biomédicas

Las señales biomédicas son señales provenientes de la observación de procesos fisiológicos en organismos vivos tales como el cuerpo humano [10]. La información presente en estas señales a menudo no se puede determinar mediante inspección visual, por lo que se emplean métodos matemáticos y estadísticos para extraer y clasificar características relevantes, las cuales en muchos casos permiten definir condiciones patológicas claves para el diseño de sistemas de diagnóstico automatizado de enfermedades. Según su naturaleza, las señales biomédicas pueden clasificarse en:

1. **Señales bioeléctricas:** registran los potenciales eléctricos originados en el ce-

rebro y el sistema nervioso y son adquiridas utilizando electrodos [11]. Algunas de las técnicas más empleadas son:

- Electroencefalograma: mide la actividad eléctrica en la corteza cerebral.
 - Electrocardiograma: mide la actividad eléctrica del corazón.
 - Electromiograma: mide la actividad eléctrica muscular.
 - Magnetoencefalograma: mide campos magnéticos producidos por la actividad eléctrica de las neuronas.
2. **Señales biomecánicas:** registran los movimientos del cuerpo. Requieren de sensores de movimiento y procesamiento durante largos períodos de tiempo.
 3. **Señales biomagnéticas:** registran campos magnéticos débiles originados por variaciones eléctricas en órganos como el corazón o los pulmones.
 4. **Señales bioquímicas:** registran mediciones químicas en tejidos vivos.

Las señales analizadas en esta investigación provienen de bases de datos EEG, por lo cual, es menéster establecer una revisión de los conceptos derivados del sistema nervioso, el cerebro y las neuronas.

2.2. El sistema nervioso

El sistema nervioso es una red biológica presente en seres humanos y animales y su objetivo principal es comunicar el encéfalo y la médula espinal con los órganos y extremidades del cuerpo. Está constituido por neuronas, células especializadas en la conducción de potenciales eléctricos, y células gliales, que brindan soporte a la red. Realiza el control de órganos, la coordinación muscular y el procesamiento de información sensorial [11]. Sus funciones se pueden clasificar según pertenezcan al Sistema Nervioso Somático (SNS), encargado de las actividades voluntarias como el movimientos de extremidades, o al Sistema Nervioso Autónomo (SNA), encargado de funciones involuntarias como la respiración, los latidos del corazón o las reacciones del cuerpo ante situaciones de peligro. El sistema nervioso humano se divide en Sistema Nervioso Central (SNC) y Sistema Nervioso Periférico (SNP):

1. **Sistema nervioso central:** red neuronal cubierta y protegida por el cráneo y la columna vertebral. Controla la mayoría de las funciones del cuerpo y procesa la información proveniente de las neuronas del SNP. Se divide en encéfalo y médula espinal:
 - a) **Encéfalo:** se ubica dentro de la estructura ósea del cráneo. Está conformado por el cerebro, el cerebelo y el bulbo raquídeo.
 - Cerebro: órgano que centraliza la actividad del sistema nervioso.
 - Cerebelo: región del encéfalo que coordina los movimientos precisos del cuerpo, el equilibrio y la postura.
 - Bulbo raquídeo: segmento del tronco encefálico que regula las funciones cardíacas, respiratorias, gastrointestinales, circulatorias, y del sistema nervioso autónomo.
 - b) **Médula espinal:** Transmite las señales provenientes del SNP al cerebro y las respuestas desde el cerebelo a los órganos locomotores.
2. **Sistema nervioso periférico:** red neuronal conformada por los terminales nerviosos del tronco, cuello y las cuatro extremidades del cuerpo. Envía impulsos eléctricos hacia el SNC en respuesta a los estímulos del ambiente.

2.2.1. El cerebro humano

El cerebro es el órgano más complejo del cuerpo humano [9], compuesto por aproximadamente cien mil millones de neuronas interconectadas. Procesa la información procedente del cuerpo y del mundo exterior. Está protegido externamente por los huesos del cráneo e internamente por el líquido cefalorraquídeo. Se constituye de las sustancias gris y blanca; la sustancia gris se compone de neuronas y se ubica en la corteza cerebral y la médula espinal, mientras que la sustancia blanca se compone de redes de axones y está presente en los tejidos subcorticales [11]. El cerebro se divide en los hemisferios derecho e izquierdo. El hemisferio derecho controla funciones relacionadas con la creatividad, la percepción, las emociones y la comunicación no verbal. El hemisferio izquierdo controla funciones relacionadas con el razonamiento

lógico y matemático, el análisis y la comunicación verbal. La corteza cerebral presenta surcos o cisuras que subdividen los hemisferios en cuatro lóbulos cerebrales [12]; frontal, parietal, occipital y temporal, como se muestra en la Figura (2.1).

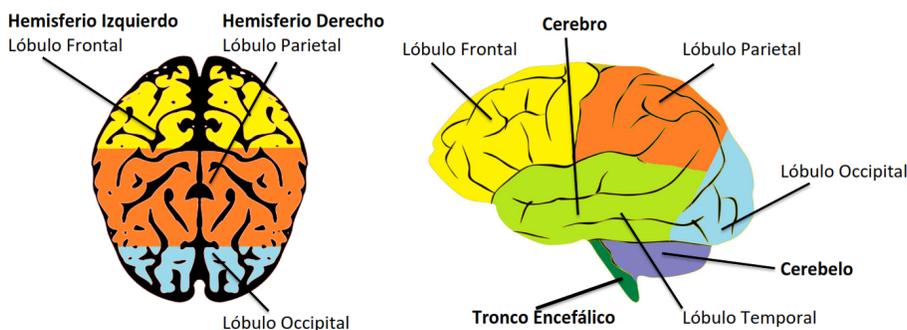


Figura 2.1 – Vista superior y hemisferio izquierdo del cerebro humano.

Las funciones asociadas a cada lóbulo se ilustran en la Figura (2.2) y se describen a continuación:

1. **Lóbulo frontal:** procesa funciones cognitivas como el lenguaje, la memoria, el pensamiento, las emociones y funciones motoras como el control del movimiento muscular. El lóbulo frontal derecho controla los movimientos de la parte izquierda del cuerpo y el frontal izquierdo los de la parte derecha.

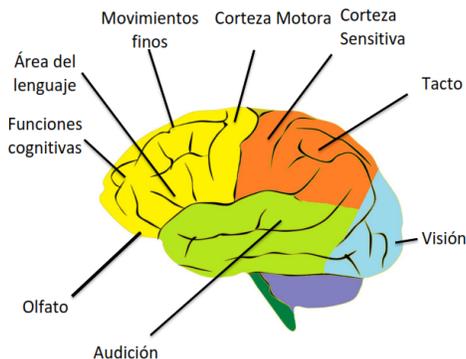


Figura 2.2 – Funciones asociadas a cada lóbulo cerebral.

2. **Lóbulo parietal:** procesa información sensorial como el tacto, la temperatura, el dolor y controla el equilibrio del cuerpo. Se sitúa detrás del lóbulo frontal.

3. **Lóbulo occipital:** analiza y procesa la información visual que recibe la retina. Se localiza en la región inferior al lóbulo parietal.
4. **Lóbulo temporal:** procesa la información auditiva, la formación de recuerdos y cumple funciones en el equilibrio y la regulación de emociones [13]. Se ubica en cada costado de la región parietal.

2.2.2. Neuronas

Las neuronas son células eucarióticas especializadas que transmiten señales químicas y eléctricas a lo largo del sistema nervioso. Se constituyen de tres partes, el soma, las dendritas y el axón tal como se ilustra en la Figura (2.3). El soma se compone del núcleo celular ubicado en el centro de la neurona y la membrana plasmática. Las dendritas son prolongaciones cortas de la célula que reciben señales provenientes de otras neuronas y las transmiten al soma. El axón es la prolongación más larga de la neurona y acaba en ramificaciones pequeñas llamadas botones sinápticos.

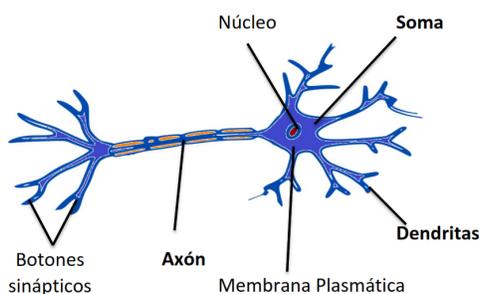


Figura 2.3 – Estructura general de una neurona.

2.2.2.1. Potencial de acción

Las neuronas producen un potencial de reposo debido a las concentraciones asimétricas de cargas iónicas de sodio, potasio, cloro y calcio en el exterior e interior de su membrana plasmática [9]. La variación en la distribución de cargas a ambos lados de la membrana genera un cambio de tensión llamado Potencial de Acción (PA) que se propaga a lo largo del axón hasta alcanzar la periferia de la neurona transmisora (presináptica), activando en los botones sinápticos la secreción de sustancias

químicas llamadas neurotransmisores [14], los cuales se unen a la neurona receptora (postsináptica), pudiendo o no desencadenar un nuevo potencial de acción en esta célula [12]. El comportamiento del PA presenta distintas fases relacionadas con su polaridad y magnitud de voltaje, como se muestra en la Figura (2.4). En la *polarización*, la neurona se encuentra en reposo y su potencial es de aproximadamente -70mV [11]. En la *despolarización*, ingresan cargas positivas a la neurona, mayoritariamente de sodio y el potencial de reposo asciende sobre -70mV . En la *sobreexcitación*, el potencial de reposo asciende sobre el umbral de -55mV , abriendo los canales de sodio y generando un PA que alcanza un valor de aproximadamente $+30\text{mV}$. En la *repolarización*, se bloquean los canales de sodio, se abren los canales de potasio [15] y el PA comienza a descender. En la *hiperpolarización*, el potencial de membrana alcanza una magnitud inferior a -70mV . En el *período refractario*, el potencial de membrana asciende nuevamente hasta alcanzar -70mV . La duración media de un PA varía entre 5 y 10 milisegundos y presenta velocidades de conducción entre 1 y 100m/s .

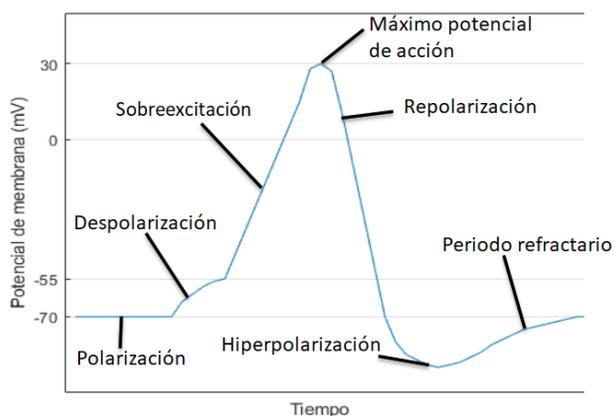


Figura 2.4 – Variación eléctrica del PA en el tiempo.

2.3. El Electroencefalograma

La electroencefalografía consiste en el registro de potenciales eléctricos generados por la actividad neuronal de la corteza cerebral mediante el uso de electrodos situados sobre la superficie del cuero cabelludo [16]. Las señales EEG son amplificadas,

digitalizadas y multiplexadas mediante el electroencefalógrafo para su grabación o almacenamiento en software [11]. El EEG es una técnica barata y no invasiva [12], sin embargo como desventaja, las señales EEG tienen baja amplitud debido a atenuaciones producidas por el cráneo y algunos tejidos, y a menudo se corrompen con impulsos provenientes de artefactos internos y externos. Los registros de señales EEG se adquieren en zonas de la corteza cerebral donde las diferencias de potencial son suficientemente grandes como para ser capturadas por electrodos superficiales.

2.3.1. Montajes EEG

Un sistema EEG convencional emplea electrodos de cloruro de plata (AgCl) con impedancias de entre 1 y $10\text{k}\Omega$ [11] requiriendo en ocasiones del uso de un gel para su fijación sobre el cuero cabelludo. Si se conecta un par de electrodos en la misma fase de amplificación, al menos uno de los dos electrodos debe ser activo y el otro puede ser activo o referencial, dando origen a los montajes de electrodos; *monopolar*, *laplaciano* y *bipolar* [7]. En el montaje monopolar los electrodos activos se conectan de manera independiente en los canales del dispositivo y se mide la diferencia de potencial con respecto a un electrodo de referencia con potencial igual a cero volts. En el montaje laplaciano la referencia es el promedio de varios electrodos próximos al electrodo a medir. En el montaje bipolar se miden las diferencias de potencial entre parejas de electrodos activos.

2.3.2. Sistema 10-20

El “Sistema Internacional de Posicionamiento de Electrodos 10-20” es el estándar de colocación de electrodos recomendado por la Federación Internacional de Sociedades de Electroencefalografía y Neurofisiología Clínica (FISE). Emplea 21 canales con sus electrodos posicionados como se ilustra en la Figura (2.5). A cada electrodo se le asigna una letra y un número según su ubicación sobre el cuero cabelludo; Fp, F, C, P, T, O y A, correspondientes a frontal polar, frontal, central, parietal, temporal, occipital y auricular [14]; los números pares e impares indican el hemisferio derecho e izquierdo, respectivamente, y la z indica los electrodos centrales. Los puntos de referencia para posicionar los electrodos son; nasión (parte superior de la nariz),

inión (hueso occipital), y preauricular derecho e izquierdo (detrás de cada oreja). En este sistema primero se sitúan los electrodos de referencia nasión-inión o preauricular derecho-izquierdo y luego se ubica el primer electrodo activo a una distancia del 10 % de la distancia entre electrodos de referencia. Los electrodos activos se sitúan entre sí a una distancia del 20 % de la distancia entre electrodos de referencia. El nombre del sistema proviene de esta particular forma de posicionamiento de los electrodos.

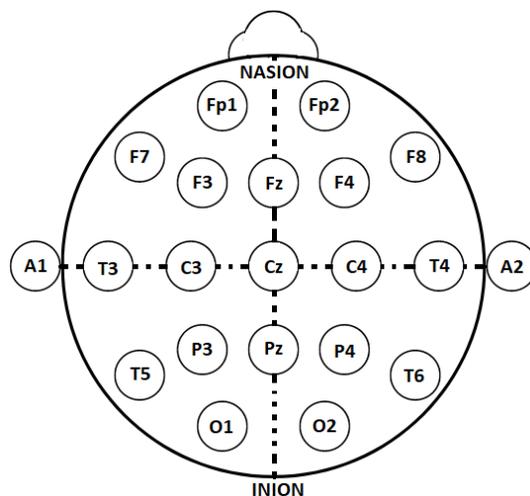


Figura 2.5 – Sistema Internacional de ubicación de electrodos 10-20.

2.4. Señales EEG

La señal medida en un electrodo es resultado de la sumatoria de impulsos eléctricos simultáneos de miles de millones de neuronas de distintas áreas del cerebro [11]. Las señales EEG son de tipo aleatorias y se representan como una gráfica compleja de la diferencia de potencial en función del tiempo [9]. El rango de frecuencias en señales EEG varía de 0.5 a 100 Hz [18] y presenta amplitudes en el rango de $5\mu\text{V}$ a $200\mu\text{V}$. Las fuentes de información de señales EEG tienen un enfoque espacial (áreas específicas de la corteza cerebral), espectral (variaciones de amplitud de frecuencia) o temporal (variaciones de tensión en intervalos de tiempo) [8]. La extracción de características puede centrarse en el análisis de la actividad oscilatoria (espectral

y espacial) o en el estudio de potenciales relacionados con eventos (temporal y espacial). La extracción por actividad oscilatoria consiste en el análisis de potenciales generados de manera espontánea con su energía concentrada en bandas de frecuencia específicas. Por otro lado, la extracción basada en potenciales relacionados con eventos consiste en analizar señales obtenidas de canales ubicados en zonas del cerebro asociadas con la realización de tareas específicas o estímulos determinados.

2.4.1. Ritmos cerebrales

Las señales EEG se descomponen en ritmos espontáneos identificados con letras del alfabeto griego; *delta*, *theta*, *alpha*, *beta* y *gamma* [7]. Aparecen cuando las neuronas asociadas se encuentran en reposo, se atenúan ante ciertos eventos y reaparecen con mayor intensidad finalizados los eventos. Además, existen ritmos tales como el *mu*, que comparten banda de frecuencia con otros pero difieren en su localización o en el estímulo que los provoca [16]. Los ritmos cerebrales son descritos a continuación.

2.4.1.1. Ritmo Delta (δ)

El ritmo delta de la Figura (2.6) presenta ondas de 0.5 a 4Hz con amplitudes entre 10 y 200 μ V. Se detecta durante el sueño profundo y la infancia. Se relaciona con actividades como la regulación del ritmo cardíaco y la digestión [19].

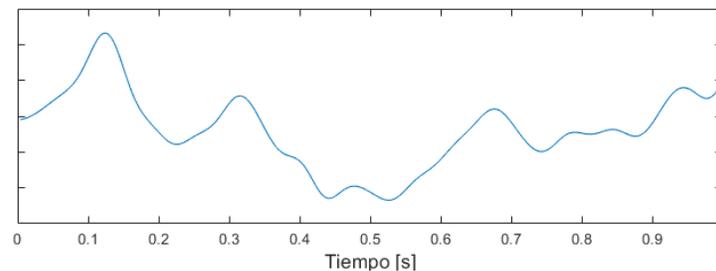


Figura 2.6 – Ondas delta con banda de frecuencia de 0.5 a 4Hz.

2.4.1.2. Ritmo Theta (θ)

El ritmo theta de la Figura (2.7) presenta ondas de 4 a 8Hz con amplitudes entre 20 y 100 μ V. Se detecta en niños y en adultos en estado de adormecimiento o sueño.

Se asocia a la meditación, las emociones, el cálculo y el estado de alerta [11].

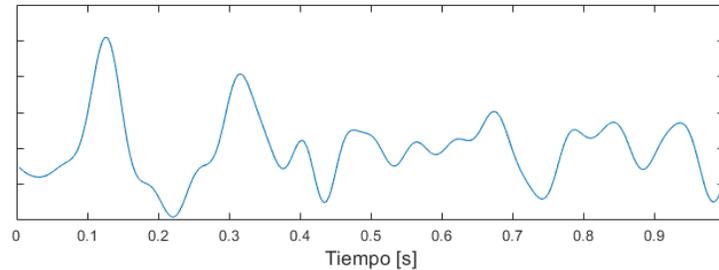


Figura 2.7 – Ondas theta con banda de frecuencia de 4 a 8Hz.

2.4.1.3. Ritmos Alpha (α) - Mu (μ)

El ritmo alpha de la Figura (2.8) presenta ondas de 8 a 13Hz con amplitudes inferiores a $50\mu\text{V}$. Se registra en sujetos en estado de relajación con los ojos cerrados pero sin sueño [19]. Muchos de los estudios disponibles en la bibliografía se centran en la caracterización del ritmo alpha a la hora de realizar la detección de crisis epilépticas. El ritmo mu comparte el mismo rango de frecuencia y amplitud de las ondas alpha, sin embargo se asocia a actividades motoras y al ritmo beta [7].

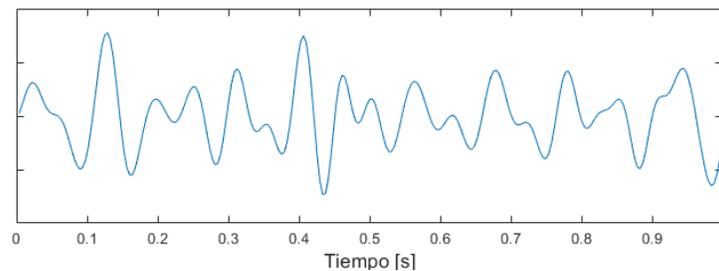


Figura 2.8 – Ondas alpha con banda de frecuencia de 8 a 13Hz.

2.4.1.4. Ritmo Beta (β)

El ritmo beta de la Figura (2.9) presenta ondas de 13 y 30Hz con amplitudes inferiores a $30\mu\text{V}$. Se asocia a la concentración mental relacionada con actividades físicas motoras y cognitivas, así como a las situaciones de pánico [9].

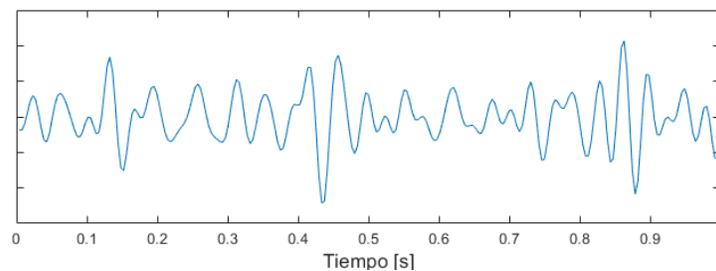


Figura 2.9 – Ondas beta con banda de frecuencia de 13 a 30Hz.

2.4.1.5. Ritmo Gamma (γ)

El ritmo gamma de la Figura (2.10) presenta ondas de 30 a 100Hz con amplitudes entre 5 y 10 μV . Se relaciona con el estado de vigilia, atención y procesos cognitivos complejos [19]. Aparece frente a estímulos sensoriales tales como sonidos y luces intensas o repetitivas.

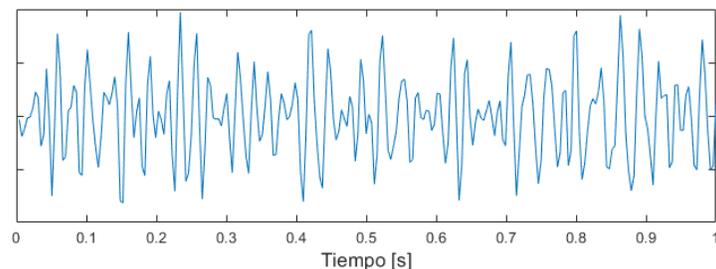


Figura 2.10 – Ondas gamma con banda de frecuencia de 30 a 100Hz.

2.4.2. Potenciales relacionados con eventos

Los Potenciales Relacionados con Eventos (ERP) se originan en respuesta a estímulos nerviosos internos o externos, tales como pensamientos, percepción o movimientos [11]. La amplitud de un ERP varía entre 1 y 40 μV alcanzando valores positivos o negativos. El registro de un ERP requiere de la aplicación reiterada del estímulo para promediar sus valores. La actividad relacionada al ERP tiene una media con valor constante, a diferencia del resto de la señal EEG que por ser de tipo aleatoria tiene una media igual a cero.

2.4.3. Artefactos

Las señales EEG son altamente susceptibles a ruidos generados por artefactos. Los artefactos son señales provenientes de actividades internas como movimientos musculares, parpadeos de ojos, señales pulmonares, circulatorias o cardíacas, y de fuentes externas como la corriente de la red, electricidad estática, electrodos defectuosos, entre otros. La eliminación de artefactos de las señales EEG es primordial ya que pueden producir amplitudes 100 veces mayores a las generadas por señales cerebrales [8], ocasionando resultados incorrectos y poco fiables en su análisis e interpretación.

2.5. Registros de EEG durante crisis epilépticas

El trastorno de la epilepsia provoca la hipersincronización de las señales nerviosas en áreas con grandes cantidades de neuronas, disparando la actividad eléctrica cerebral. La amplitud de la señal EEG incrementa su valor durante la crisis y hasta algunos segundos después de terminada. La señal EEG en una crisis epiléptica presenta tres fases: *preictal*, *ictal* y *postictal* [7]. La fase *preictal* es una fase de varios minutos, previa a la crisis epiléptica o fase *ictal*, mientras que la fase *postictal* corresponde al momento posterior a la crisis. En la Figura (2.11) se muestra un fragmento de registro EEG de 5 minutos de duración adquirido de la grabación número 3 en la posición F7-T7 del paciente número 1 de la base de datos CHB-MIT. El inicio y término de la crisis epiléptica está delimitado por líneas rojas segmentadas.

A nivel de Densidad Espectral de Potencia (PSD), la amplitud de la señal aumenta en la banda de 0 a 100Hz debido tanto a las convulsiones generadas por la crisis como a los movimientos de reacción del paciente frente a esta [7]. La energía asociada a la actividad epiléptica se libera en valores de frecuencia de 0.5 a 25Hz, mientras que la energía asociada a actividad motora voluntaria e involuntaria aumenta en la banda superior a 25Hz. En el periódograma de la Figura (2.12) se compara la PSD calculada de un segmento de señal con crisis epiléptica y otro segmento sin crisis. Se evidencia el aumento de la potencia en aproximadamente 20dB a lo largo de todo el ancho de banda del segmento con crisis, respecto al segmento sin crisis. La señal utilizada proviene del registro n°4 del paciente 1 de la base de datos CHB-MIT.

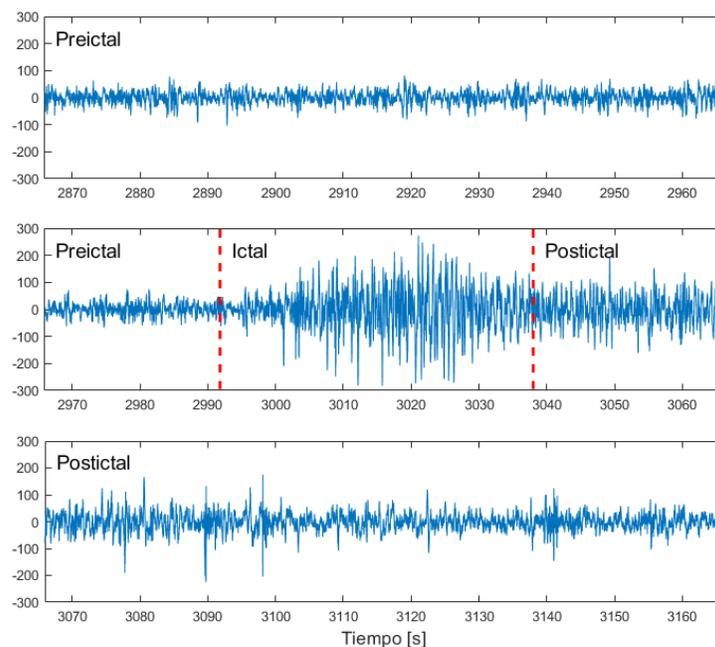


Figura 2.11 – Registro EEG de 5 minutos de duración con crisis epiléptica y sus fases.

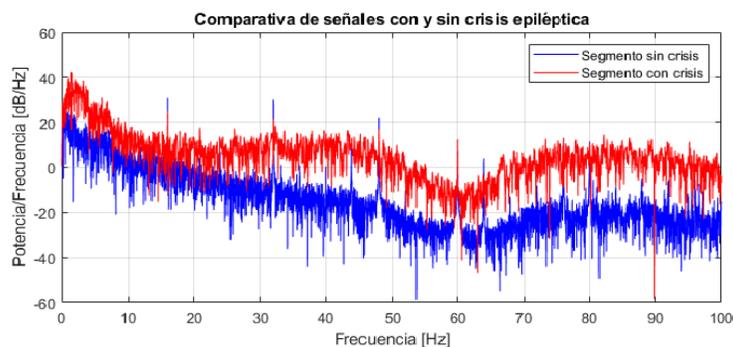


Figura 2.12 – Comparación PSD en [dB/Hz] de segmento EEG con y sin crisis epiléptica.

2.6. Bases de datos de registros EEG utilizadas

Las grabaciones EEG con crisis epilépticas utilizadas en este trabajo provienen de las bases de datos públicas del Hospital de Niños de Boston y del Hospital Universitario de Helsinki. Fueron adquiridas de pacientes con epilepsia y algunos registros

contienen crisis epilépticas. En ambas bases de datos los neurofisiólogos marcaron el inicio y término de los episodios con crisis.

2.6.1. A dataset of neonatal EEG recordings with seizure annotations.

Los archivos EEG de esta base de datos se obtuvieron de recién nacidos en la UCIN del Hospital Universitario de Helsinki entre 2010 y 2014 [20]. La cohorte de estudio fue de 79 pacientes con edades de gestacionales de 32 a 45 semanas. Los registros EEG tienen duraciones entre 64 a 96 minutos con una media de grabación de 74 minutos. Las señales se digitalizaron con una frecuencia de muestreo de 256Hz y se emplearon 19 electrodos posicionados según el sistema internacional 10-20.

2.6.2. CHB-MIT Scalp EEG Database.

Esta base de datos fue registrada en el Hospital de Niños de Boston (CHB) y consiste en grabaciones EEG de sujetos pediátricos con crisis epilépticas intratables [21]. Las señales fueron recogidas de 22 sujetos, 5 de ellos varones con edades de 3 a 22 años y 17 mujeres con edades entre los 1.5 y 19 años. Cada caso contiene entre 9 y 42 archivos EDF por sujeto. Las señales EEG tienen una duración de 60 minutos y se digitalizaron con una frecuencia de muestreo de 256Hz y una resolución de 16 bits. Se utilizó el sistema internacional 10-20 para el posicionamiento de electrodos.

2.7. Estado del arte

Los estudios disponibles en la bibliografía ilustran el uso de diversos métodos de procesamiento de señales para realizar la detección de crisis epilépticas en señales EEG, incrementando considerablemente la precisión de los diagnósticos y disminuyendo los recursos y tiempos de análisis. En [3], Zhou, Tian, Cao, Wang, Niu, Hu, Guo y Xiang utilizaron una Red Neuronal Convolutiva (CNN) para distinguir los segmentos ictal, preictal e interictal en señales EEG. Se realizaron dos experimentos de clasificación binaria (interictal vs. preictal e interictal vs. preictal) y un experimento de clasificación de tres clases (interictal vs. preictal vs. ictal) en función del tiempo y en función de la frecuencia. Las precisiones promedio oscilaron entre

92,3% y 97,5% para señales en frecuencia mientras que para señales en el tiempo los valores oscilaron entre 47,9% y 91.1%, obteniendo mayor precisión en la detección de crisis epilépticas sobre señales en función de la frecuencia. En [4], Selvathi y Meera proponen la detección de crisis epilépticas utilizando Transformada Wavelet Discreta (DWT) y Máquina de Vectores de Soporte (SVM). En este trabajo la señal fue descompuesta en siete niveles usando DWT para obtener las sub-bandas de frecuencia de los ritmos cerebrales espontáneos delta, alpha, theta, beta y gamma. Las características estadísticas extraídas fueron media y varianza. La clasificación de características fue realizada con SVM, obteniendo un nivel de precisión de un 95.6%. En [5], Anand, Jaiswal y Ghosh proponen un diagnóstico automático de la epilepsia basado en la extracción de características estadísticas. Las señales fueron filtradas para eliminar componentes de corriente continua utilizando filtros paso bajo y paso alto para eliminar los artefactos de la red. Se disminuyó el ruido de la señal empleando Transformada de Hilbert-Huang (HHT) y se utilizó Empirical Wavelet Transform (EWT) para la descomposición de la señal EEG en sub-bandas de frecuencia. Se extrajeron las características; media, varianza, asimetría, curtosis y entropía. Las características se clasificaron a través de SVM utilizando los núcleos Base Radial Gaussiana y Polinomial. El método alcanzó un nivel de precisión del 100%. En [6], Panda, Khobragade, Jambhule, Jengthe, Pal, y Gandhi proponen un método de detección basado en el uso de Wavelet Transform para la extracción de características y SVM para la clasificación de crisis epilépticas en señales EEG. Se analizaron cinco tipos de señales EEG; de sujetos saludables, sujetos con los ojos abiertos, con los ojos cerrados, pacientes con epilepsia, y señales con convulsiones. Las señales fueron preprocesadas y descompuestas usando DWT hasta el quinto nivel de descomposición. Se extrajeron las características energía, entropía y desviación estándar. La detección de actividad epiléptica en señales EEG alcanzó un valor de precisión cercano al 91.2% en la clasificación. En [22], Kumar, Kanhangad y Pachori realizaron la Descomposición Modal Empírica (EMD) de las señales para obtener Funciones de Modo Intrínseco (IMF). Se calcularon los Patrones Locales Multinivel (MLP) para cada IMF estableciendo comparaciones con un valor de muestra de la señal y su vecindad local. Los conjuntos de características se construyeron calculando

los histogramas MLP. Finalmente se utilizó un clasificador de K-Vecinos Cercanos (KNN) para clasificar las señales EEG como convulsiones o libres de convulsiones. La precisión alcanzada por este método fue de 98,67%. En [23], Chowdhury, Hos-sain, Fattah y Shahnaz realizaron la detección de crisis epilépticas en señales EEG utilizando una CNN 1-D con arquitectura de aprendizaje profundo para selección automatizada de características y clasificación. La arquitectura se implementó para varios tipos de señales con crisis y sin crisis epiléptica obteniendo resultados con alta precisión y sensibilidad en comparación con los métodos basados en la selección manual de características. El algoritmo alcanzó valores de precisión del 99.4%. En [24], Aldana, Hunyadi, Reyes, Rodríguez y Van Huffel proponen un método para la detección de ataques epilépticos no-convulsivos. Para diferenciar entre una señal EEG normal y una con ataque, se empleó un clasificador KNN, SVM con kernel de base radial y Análisis Discriminante Lineal (LDA). Las características para clasificación se obtuvieron realizando la Descomposición Poliádica Canónica (CPD) y Descomposición en Términos en Bloque (BTD) de las señales EEG para ser representadas como un tensor de tercer orden. Para expandir la señal EEG en un tensor, se utilizó HHT y WT. El algoritmo fue medido en una base de datos EEG de cuero cabelludo de 139 crisis epilépticas de diferentes duraciones. Los resultados experimentales determinaron que las representaciones de tensores mediante HHT y análisis CPD proporcionaron un marco más adecuado para la detección de ataques epilépticos no convulsivos. El uso de kernel de base radial en el clasificador SVM mostró el mejor desempeño, alcanzando valores de precisión sobre el 98%. En [25], Gupta, Singh y Karlekar realizaron la detección de ataques epilépticos en señales EEG en tres etapas. En la primera etapa se elaboró una estructura de banco de filtros multitasa usando vectores base de la Transformada Coseno Discreta (DCT), obteniéndose los ritmos cerebrales delta, theta, alpha, beta y gamma. En la segunda etapa, estos ritmos cerebrales fueron modelados estadísticamente a través de Movimiento Browniano Fraccional (FBM) y Ruido Gaussiano Fraccional (FGN). Los resultados de estos procesos fueron modelados usando exponente de Hurst (H). En la tercera etapa, el valor del exponente de Hurst y los parámetros del Promedio Móvil Autorregresivo (ARMA) se utilizaron como características en el diseño de un clasificador binario

SVM para identificar segmentos EEG pre-ictal, inter-ictal e ictal. El desempeño del algoritmo alcanzó valores de precisión cercanos al 97 %. En [26], Hassanpour, Mesbah y Boashash investigaron el desempeño de cuatro métodos no-paramétricos de detección de ataques epilépticos en señales EEG adquiridas de 4 pacientes recién nacidos. El primer método realizó la detección de crisis epilépticas a través del análisis de intervalos entre espigas epilépticas (crestas que aparecen durante la crisis) en señales EEG en el dominio Tiempo-Frecuencia (TF). El desempeño de este método fue comparado con las otras tres técnicas de detección de ataques epilépticos. El segundo método se basó en el análisis en el dominio del tiempo, calculándose la función de Autocorrelación sobre épocas de corta duración de la señal EEG. El tercer método se basó en el análisis espectral de la señal EEG para realizar la detección de descargas periódicas. El cuarto método empleado se apoyó en la técnica de Análisis de Espectro Singular (SSA), realizando la selección de características del subespacio de la señal. Los tres últimos métodos se emplearon asumiendo que las señales EEG de recién nacidos son cuasi-estacionarias. El mejor desempeño fue alcanzado por el algoritmo de detección basado en la técnica TF, logrando valores de precisión del 91 %. En [27], Vidyaratne e Iftekharuddin proponen un método para realizar la detección de ataques epilépticos en tiempo real, usando señales EEG adquiridas del cuero cabelludo e intracraneales. La técnica consistió en obtener la multiresolución armónica y las características de autosimilitud fractal de las señales EEG. La descomposición de las señales se realizó mediante la Harmonic Wavelet Packet Transform (HWPT) para alcanzar buena resolución en alta frecuencia. Por otro lado, se estimó la Dimensión Fractal (FD) para capturar los patrones repetitivos de autosimilitud en la señal EEG. Las características de energía de HPWT y FD de todos los canales EEG se organizaron en distintas épocas según su información espacial, centrándose en la ubicación de los electrodos situados en el cráneo. El vector de características final combinó las configuraciones de características de cada época dentro de una ventana móvil que reflejó en el tiempo la información de la señal EEG. Por último, se utilizó Máquina de Vectores de Relevancia (RVM) para clasificar los vectores de características. El algoritmo alcanzó niveles de sensibilidad del 95 %, una media de 0.1 falsos positivos por hora, una media de 1.89 segundos de tardanza en la detección de crisis epilépticas

y una precisión del 99.8 %. En [28], Zabihi, Kiranyaz, Ince y Gabbouj proponen una técnica de detección de ataques epilépticos basada en la selección de subconjuntos de características óptimos y el entrenamiento de clasificadores especializados para cada paciente. El método utilizó conjuntos de múltiples características en el dominio del tiempo, dominio de la frecuencia, dominio tiempo-frecuencia, y características no lineales. Por medio de Maximización de Información Mutua Condicional (CMIM) se seleccionaron los subconjuntos de características óptimas en base a los cuales se entrenó un clasificador SVM con kernel lineal. Los niveles de precisión alcanzados por este método variaron entre 97.61 % y 99.83 %. En [29], Zarjam, Mesbah y Boashash compararon dos distintos enfoques para realizar la detección de crisis epilépticas en señales EEG adquiridas de recién nacidos. El primer enfoque propuesto se basó en la discriminación entre los estados de crisis y no-crisis mediante cálculo de distancia TF entre los segmentos consecutivos en la señal EEG. En este método se emplearon tres distintas mediciones TF y tres diferentes Distribuciones Tiempo-Frecuencia (TFD). El segundo enfoque propuesto se centró en el uso de DWT. Los conjuntos de características obtenidos se clasificaron mediante el uso de una Red Neuronal Artificial (ANN) para etiquetar las señales EEG como crisis o no-crisis epiléptica. Los resultados experimentales alcanzaron niveles de precisión del 96 %.

2.8. Conclusión del capítulo

Los antecedentes presentados en este capítulo proporcionan importantes conceptos que sustentan la metodología de trabajo y los procedimientos experimentales llevados a cabo para realizar la detección de ataques epilépticos en señales EEG. En los siguientes capítulos, principalmente en el capítulo 4 titulado Experimentación y Resultados, tales conceptos son citados a menudo, por lo tanto su revisión y comprensión resultan fundamentales. La metodología de trabajo y los modelos matemáticos utilizados para el procesamiento de señales EEG se plantean a continuación en el Marco Teórico de esta investigación, correspondiente al Capítulo 3 de la obra.

CAPÍTULO 3

Marco teórico

3.1. Metodología propuesta

El análisis de señales EEG para la detección de crisis epilépticas implica la utilización de distintas técnicas matemáticas combinadas. La comprensión total de los contenidos ilustrados en este capítulo requiere en gran medida de conocimientos en las áreas de procesamiento digital de señales, cálculo infinitesimal, álgebra lineal y estadística. La metodología empleada en esta investigación para realizar la detección de ataques epilépticos en señales EEG se centra en cuatro pilares fundamentales los cuales son: *preprocesamiento de señal*, *descomposición de señal*, *extracción de características* y *clasificación de características*. El preprocesamiento se realiza empleando un filtro Savitzky-Golay que mejora la relación señal-ruido de la señal original [30] y elimina los artefactos presentes en las señales EEG. Con el fin de reducir la cantidad de datos para realizar la extracción de características, la señal prefiltrada se descompone en distintos niveles para luego construir las señales de los ritmos cerebrales espontáneos, utilizando la Transformada Wavelet Discreta. Las características son extraídas en intervalos marcados como crisis epiléptica e intervalos sanos, definiendo dos tipos de clases. Luego, se entrena un clasificador binario Máquina de Vectores de Soporte con las características pertenecientes a ambas clases para el reconocimiento de datos como “crisis epiléptica” o “no crisis”. Finalmente, para determinar los niveles de precisión del algoritmo, se realiza la detección de crisis epilépticas sobre nuevos conjuntos de datos provenientes de señales EEG no caracterizadas. El diagrama de flujo de este procedimiento se ilustra en la Figura (3.1).

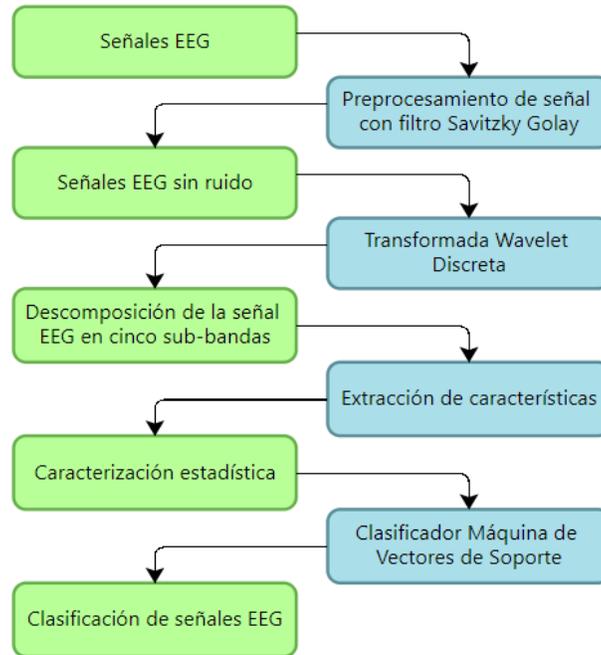


Figura 3.1 – Diagrama de flujo de la metodología propuesta en la investigación.

Determinados los pasos a seguir en el desarrollo del algoritmo, se describen las técnicas de procesamiento de señales a emplear a lo largo de esta investigación.

3.2. Relación señal-ruido

Las señales EEG tienen por lo general una baja Relación Señal-Ruido (SNR), siendo altamente susceptibles a atenuaciones y a ruidos provenientes de artefactos. Si se tiene una señal $x[n]$, la acción de agregar ruido $w[n]$ a la señal se expresa como:

$$y[n] = x[n] + w[n] \quad n = 1, 2, \dots, N \quad (3.1)$$

donde $y[n]$ es la señal ruidosa de salida y N es la cantidad de muestras de la señal. La *potencia media* P de cualquier señal se obtiene a través de la expresión:

$$P = \frac{1}{N} \sum_{n=1}^N (x[n])^2 \quad (3.2)$$

Utilizando la definición matemática de la SNR se puede calcular la magnitud en decibelios [dB] de la proporción entre la potencia de la señal, denotada por P_s , y la potencia del ruido presente en esta, denotada por P_n , de modo tal que:

$$SNR_{dB} = 10 \log \left(\frac{P_s}{P_n} \right) \quad (3.3)$$

Si el valor calculado en (3.3) es positivo, a mayor distancia del cero, mejor SNR tiene la señal. Si por el contrario, el valor de (3.3) es próximo a cero o negativo, la señal tiene una baja SNR. Habitualmente, para mejorar la SNR, se emplean filtros digitales.

3.2.1. Coeficiente de correlación muestral

En procesamiento digital, el *coeficiente de relación muestral* es utilizado para medir la similitud entre dos señales y se denota por r_{xy} . Dada una secuencia de n pares de datos, tal que $\{(x_i, y_i)\}$, con $i = 1, 2, \dots, n$, se define el coeficiente de correlación muestral como:

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3.4)$$

donde x_i e y_i son puntos muestrales y \bar{x} e \bar{y} son las respectivas *medias muestrales* de las secuencias. Los valores de r_{xy} fluctúan entre $[-1,1]$. Si $r = 1$, la correlación es positiva perfecta y las variables se encuentran en *relación directa*. Si $0 < r < 1$, entonces existe una correlación positiva. Si $r = 0$, no existe relación lineal entre las variables. Si $-1 < r < 0$, existe una correlación negativa. Si $r = -1$, la correlación es negativa perfecta y las variables se encuentran en *relación inversa*.

3.2.2. Filtro Savitzky-Golay

El filtro digital Savitzky-Golay (SG) es un filtro de Respuesta Finita al Impulso (FIR), de tipo paso-bajo no causal, utilizado ampliamente en la eliminación de ruido

en señales biomédicas. Fue propuesto en 1964 por A. Savitzky y M. J. Golay. Una de las ventajas del filtro SG en comparación a otros tipos de filtros FIR es que suaviza la señal sin alterar su estructura original y aumenta el SNR preservando las componentes de alta frecuencia. El filtrado SG se basa en la aproximación por mínimos cuadrados locales [31], donde un filtro de media móvil ponderado ajusta una ventana de puntos de datos adyacentes convolucionándolos con un polinomio de bajo orden. Sea $x[n]$ una secuencia de muestras, considerando una ventana simétrica de longitud $2M + 1$ centrada alrededor del punto $n = 0$ y siendo M la cantidad de muestras a la derecha o izquierda del punto central, es posible determinar los coeficientes del polinomio de la expresión (3.5):

$$p(n) = a_0 + a_1n + a_2n^2 + \dots + a_Nn^N = \sum_{k=0}^N a_k n^k \quad (3.5)$$

donde N y a_k , denotan el orden y el k -ésimo coeficiente del polinomio, respectivamente. El polinomio se ajusta a las muestras de la ventana minimizando el Error Cuadrático Medio (MSE) dado por ϵ_N , de forma tal que:

$$\epsilon_N = \sum_{n=-M}^M (p(n) - x[n])^2 = \sum_{n=-M}^M \left(\sum_{k=0}^N a_k n^k - x[n] \right)^2 \quad (3.6)$$

Los coeficientes óptimos del polinomio (3.5) se encuentran derivando ϵ_N respecto a a_i con $i = 0, 1, \dots, N$ para un total de $N + 1$ coeficientes, e igualando a cero:

$$\frac{\partial \epsilon_N}{\partial a_i} = \sum_{n=-M}^M 2n^i \left(\sum_{k=0}^N a_k n^k - x[n] \right) = 0 \quad (3.7)$$

Resolviendo (3.7), se obtiene un sistema de $N + 1$ ecuaciones con $N + 1$ incógnitas a través del cual se pueden calcular los valores de los coeficientes a_k :

$$\sum_{k=0}^N \left(\sum_{n=-M}^M n^{i+k} \right) a_k = \sum_{n=-M}^M n^i x[n], \quad i = 0, 1, \dots, N \quad (3.8)$$

Para resolver las incógnitas de las ecuaciones de (3.8) debe cumplirse que $2M \geq N$ y que la longitud de ventana $2M + 1$ sea siempre impar. La matriz C_n de coeficientes de convolución también puede ser calculada a través de:

$$C_n = GA^\top, \quad G = (A^\top A)^{-1} \quad (3.9)$$

donde A es un vector fila, tal que:

$$A = \{n^i\}, \quad -M \leq n \leq M, \quad i = 0, 1, \dots, N \quad (3.10)$$

La elección de un filtro SG adecuado depende de la longitud de ventana $2M + 1$ y del orden N del polinomio. Al escoger un orden mayor en el polinomio se conserva un mayor número de momentos centrales de la señal pero a la vez se compromete una mayor parte de la respuesta de alta frecuencia del filtro.

3.3. Caracterización de señales

Dado que las señales EEG suelen ser altamente dimensionales y cuentan con grandes volúmenes de datos, la extracción de características estadísticas sobre la señal base tiene un alto costo computacional. Existen diferentes métodos de descomposición de la señal en subconjuntos de modo tal que se conservan las características relevantes de la señal, reduciendo su extensión y la cantidad de información redundante contenida. Los métodos de análisis y descomposición pueden ser en función del tiempo, de la frecuencia, tiempo-frecuencia combinados y métodos estadísticos. La metodología de este trabajo contempla el uso del análisis tiempo-frecuencia.

3.3.1. Análisis tiempo frecuencia

Las señales EEG son señales de tipo no-estacionario, es decir, su frecuencia varía en el tiempo. Si estas señales se analizan utilizando la Transformada Discreta de Fourier (DFT), se logra obtener la representación total de su contenido espectral sin embargo, no es posible determinar los instantes en que se producen variaciones de frecuencia. El algoritmo Transformada Rápida de Fourier (STFT) opera sobre

ventanas de señal cortas, consiguiendo representaciones espectrales localizadas en el dominio del tiempo. No obstante, el STFT tiene una respuesta de frecuencia limitada, determinada por la longitud de la ventana de análisis. Para realizar un análisis de señal de manera más flexible, se utiliza la Transformada Wavelet [32].

3.3.2. Transformada Discreta de Fourier

La Transformada Discreta de Fourier es un caso particular de la Transformada de Fourier calculada para N cantidad de muestras de una señal discreta de duración finita. La secuencia obtenida usando DFT se denota como $\tilde{x}[n]$ y se expresa mediante:

$$\tilde{x}[n] = \begin{cases} \frac{1}{N} \sum_{k=0}^{N-1} \tilde{X}[k] e^{j(2\pi/N)nk} & \text{para } 0 \leq n \leq N-1 \\ 0, & \text{para cualquier otro valor} \end{cases} \quad (3.11)$$

donde $\tilde{X}[k]$ es la representación del contenido de frecuencia de la señal. La ecuación (3.11) se conoce como Transformada Inversa Discreta de Fourier o *transformada de síntesis*. Al mismo tiempo, la *transformada de análisis* está definida por:

$$\tilde{X}[k] = \begin{cases} \sum_{n=0}^{N-1} \tilde{x}[n] e^{-j(2\pi/N)nk} & \text{para } 0 \leq k \leq N-1 \\ 0, & \text{para cualquier otro valor} \end{cases} \quad (3.12)$$

El cálculo de la DFT para ventanas de señal cortas y de longitud fija se conoce como Transformada Rápida de Fourier o STFT [38].

3.3.3. Transformada Wavelet

La Transformada Wavelet es una representación multiresolución de señales. La Transformada Wavelet emplea ventanas de dimensiones variables para descomponer la señal de entrada en subconjuntos de señales con información en el dominio del tiempo y la frecuencia, denominados coeficientes de aproximación y detalle. Los coeficientes de aproximación representan ventanas de tiempo largo con alta resolución

en bajas frecuencias mientras que los coeficientes de detalle representan ventanas de tiempo corto con información en altas frecuencias. La Transformada Wavelet puede ser de dos tipos, *Transformada Wavelet Continua* y *Transformada Wavelet Discreta*.

3.3.3.1. Transformada Wavelet Continua

La Transformada Wavelet Continua (CWT) expresa una señal analógica $x(t)$ como una expansión de coeficientes del producto interno entre la señal y las versiones desplazadas y escaladas de una función *wavelet madre* denotada por ψ [32]. La wavelet madre contiene todas las funciones wavelet de una base ortonormal definida en $\mathbb{L}^2(\mathbb{R})$, obtenidas a partir del escalado o desplazamiento en el tiempo de $\psi_{a,b}(t)$. Estas funciones se denominan átomos wavelet y se expresan como:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi \left(\frac{t-b}{a} \right) \quad (3.13)$$

La CWT de una señal se define como la integral en el tiempo de la señal de entrada $x(t)$ por la función $\psi_{a,b}(t)$, por lo tanto:

$$\text{CWT}(a,b) = \int_{-\infty}^{\infty} x(t) \psi_{a,b}(t) dt = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{|a|}} \psi \left(\frac{t-b}{a} \right) dt \quad (3.14)$$

donde a y b son los parámetros de escalado en frecuencia y desplazamiento en el tiempo, respectivamente. Las wavelets madre pueden ser distintas funciones, tales como Haar, Daubechies o Symmlet, entre otras.

3.3.3.2. Transformada Wavelet Discreta

Determinar las posibles escalas requeridas por CWT para representar una señal en particular implica la realización de complejos cálculos. Lo anterior se resuelve utilizando la *descomposición por octavas* [33], método en el que los escalados y desplazamientos se realizan en potencias de dos para cumplir con el criterio de Nyquist y donde el máximo nivel de descomposición se determina en función de la frecuencia de muestreo de la señal. Si en la expresión (3.13) los valores a y b son reemplazados

por 2^{-j} y $k2^{-j}$, respectivamente, se obtiene la familia de funciones *wavelets diádicas* definidas por:

$$\psi_{j,k}(t) = \frac{1}{\sqrt{|2^{-j}|}} \psi\left(\frac{t - k2^{-j}}{2^{-j}}\right) \quad (3.15)$$

Resolviendo (3.15), las funciones wavelets diádicas se expresan como:

$$\psi_{j,k}(t) = 2^{\frac{j}{2}} \psi(2^j t - k), \quad j, k \in \mathbb{Z} \quad (3.16)$$

La integral de la expresión (3.14) ahora puede ser reescrita para una función diádica:

$$\text{DWT}(j, k) = \int_{-\infty}^{\infty} x(t) \psi_{j,k}(t) dt = \int_{-\infty}^{\infty} x(t) 2^{\frac{j}{2}} \psi(2^j t - k) dt \quad (3.17)$$

La expresión de (3.17) es también conocida como Transformada Wavelet Discreta, cuya forma definida para (3.15) se representa como:

$$\text{DWT}(j, k) = \frac{1}{\sqrt{|2^j|}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t - 2^j k}{2^j}\right) dt \quad (3.18)$$

Además de las funciones wavelet de (3.16), es posible crear un conjunto de funciones de escala $\phi_{j,k}(t)$ que tienen la forma:

$$\phi_{j,k}(t) = 2^{\frac{j}{2}} \phi(2^j t - k), \quad j, k \in \mathbb{Z} \quad (3.19)$$

Las funciones wavelet madre $\psi_{j,k}(t)$ y funciones de escala $\phi_{j,k}(t)$ dependen de los filtros paso-alto $\psi(t)$ y paso-bajo $\phi(t)$. Debido a la dificultad de operar la DWT en forma continua, se vuelve necesario realizar la discretización de esta, cambiando la integral por una aproximación por sumatorias. La señal $x(t)$ puede ser representada por lo tanto como las sumatorias de las funciones wavelet y las funciones de escala:

$$x(t) = \sum_{n=1}^k \sum_{m=1}^j D_{j,k} \psi(t) + \sum_{n=1}^k \sum_{m=1}^j A_{j,k} \phi(t) \quad (3.20)$$

siendo $A_{j,k}$ los *coeficientes de aproximación* y $D_{j,k}$ los *coeficientes de detalle*.

3.3.3.3. Transformada Wavelet para señales EEG

La DWT para una señal digital se obtiene realizando el filtrado sucesivo de la señal, mediante series de filtro paso-bajo y paso-alto. La suma de convolución de un filtro paso-bajo $g[n]$ y un filtro paso-alto $h[n]$ con una señal $x[n]$ se determina por:

$$\begin{aligned} A_i[n] &= (x * g)[n] = \sum_{k=-\infty}^{\infty} x[k]g[n-k] \\ D_i[n] &= (x * h)[n] = \sum_{k=-\infty}^{\infty} x[k]h[n-k] \end{aligned} \quad (3.21)$$

donde $A_i[n]$ y $D_i[n]$ son los *coeficientes de Aproximación y Detalle*, respectivamente. Para cumplir con el criterio de Nyquist en las descomposiciones wavelet, la salida de cada filtro de (3.21) debe ser *diezmada* por un factor de 2, lo cual se expresa como:

$$\begin{aligned} A_i[n] &= \sum_{k=-\infty}^{\infty} x[k]g[2n-k] \\ D_i[n] &= \sum_{k=-\infty}^{\infty} x[k]h[2n-k] \end{aligned} \quad (3.22)$$

Obtenidos los coeficientes A_1 y D_1 del primer nivel en (3.22), puede repetirse el procedimiento sobre A_1 y D_1 para obtener los coeficientes A_2 y D_2 del segundo nivel y así sucesivamente para el resto de coeficientes [32]. Este modelo de descomposición en cascada se conoce como *banco de filtros* y se ilustra en la Figura (3.2).

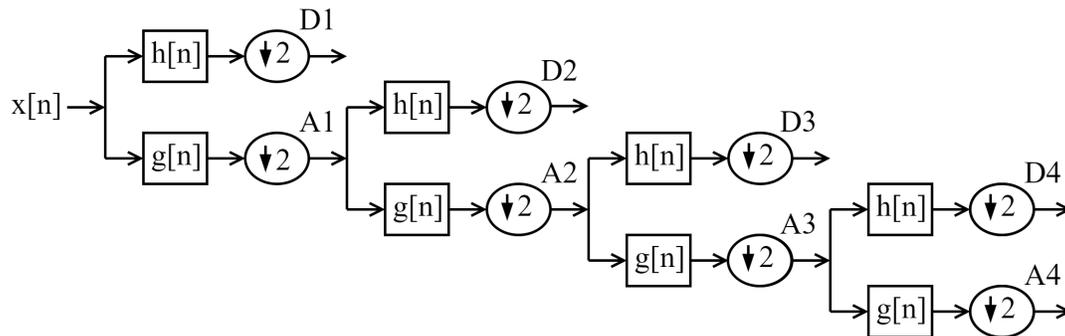


Figura 3.2 – Diagrama en bloques del banco de filtros de descomposición DWT.

3.3.4. Extracción de características estadísticas

La extracción de características se realiza sobre coeficientes wavelet de segmentos x_i de N muestras marcados por neurofisiólogos como “crisis epiléptica” y “no crisis”. El cálculo sobre ventanas de tiempo de un segundo con solapamiento de media ventana origina los subconjuntos de datos para clasificación. Las funciones a calcular son:

- Media (\bar{x}):

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (3.23)$$

- Varianza (σ^2):

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (3.24)$$

- Coeficiente de asimetría (A):

$$A = \frac{1}{N} \sum_{i=1}^N \left[\frac{(x_i - \bar{x})}{\sigma} \right]^3 \quad (3.25)$$

- Coeficiente de curtosis (K):

$$K = \frac{1}{N} \sum_{i=1}^N \left[\frac{(x_i - \bar{x})}{\sigma} \right]^4 \quad (3.26)$$

- Entropía de Shannon (H):

$$H = - \sum_{i=1}^N x_i \ln(x_i) \quad (3.27)$$

- Energía de la señal (E):

$$E = \sum_{n=1}^N (x[n])^2 \quad (3.28)$$

3.4. Aprendizaje de máquina

El Aprendizaje de Máquina (ML) es un área de estudio de la Inteligencia Artificial (AI) cuyo objetivo es el desarrollo de técnicas de aprendizaje de computadoras.

Los modelos ML se agrupan en las familias de algoritmos; *aprendizaje supervisado*, *aprendizaje profundo* y *aprendizaje por refuerzo*, descritos en las próximas secciones.

3.4.1. Aprendizaje supervisado:

El Aprendizaje Supervisado (SL) agrupa algoritmos modelados en base a *conjuntos de entrenamiento* etiquetados. Los pasos para la implementación del SL son:

1. **Selección de conjuntos de entrenamiento:** determinar la naturaleza de los datos a utilizar y los segmentos de datos representativos de cada clase.
2. **Selección del modelo:** elegir un modelo SL adecuado en base a la naturaleza de los datos y la finalidad requerida. Los modelos SL más comunes son:
 - **Árbol de Decisión:** modelo que divide el conjunto de datos de muestra en subconjuntos en función de la variable de entrada más significativa.
 - **Bosques Aleatorios:** modelo constituido de múltiples árboles de decisión.
 - **Clasificadores Naive Bayes:** modelo basado en el teorema de Bayes que clasifica según varias probabilidades independientes asociadas a un evento.
 - **K-Vecinos más Cercanos:** modelo que clasifica un punto de interés en función de las clases del conjunto de datos más próximo en distancia.
 - **Máquinas de Vectores de Soporte:** modelo enfocado en la construcción de hiperplanos de separación óptima entre las diferentes clases de datos.
3. **Entrenamiento del modelo:** obtener la función o las funciones de decisión del modelo determinadas por los conjuntos de datos de entrenamiento.
4. **Prueba del modelo:** evaluar el comportamiento del modelo utilizando conjuntos de datos desconocidos.

3.4.2. Aprendizaje profundo

El Aprendizaje Profundo (DL) se enfoca en la construcción de algoritmos sobre conjuntos de datos sin etiquetar, siendo el propio algoritmo el encargado de su recopilación, análisis e interpretación. En general, DL agrupa modelos de *redes neuronales*

con múltiples capas de entrada y salida, y capas intermedias ocultas. La implementación de un modelo DL requiere del cumplimiento de las siguientes condiciones:

1. **Cantidades de información:** aumentar el número de capas del modelo DL incrementa su efectividad, lo cual exige grandes volúmenes de datos.
2. **Capacidad de cómputo:** dadas las cantidades de datos de entrenamiento, los modelos DL generalmente requieren de alto poder de procesamiento.

Los pasos para la implementación de DL son los mismos que los del apartado 3.4.1 para el caso SL con excepción del paso 1. Los modelos DL más utilizados son:

- Perceptron: Unidad básica de una red neuronal consistente en un modelo de neurona artificial construido a partir de un discriminador lineal.
- Red Neuronal Artificial: modelo que transforma datos desde la entrada a la salida por medio de una serie de capas ocultas interconectadas.
- Red Neuronal Recurrente: modelo de red neuronal con retroalimentación de las capas de salida a la capa de entrada (memoria).
- Red Neuronal Convolutiva: modelo de red neuronal constituido por múltiples capas de filtros convolucionales de una o más dimensiones.

3.4.3. Aprendizaje por Refuerzo

El Aprendizaje por Refuerzo (RL) es un enfoque reciente de ML asentado en conceptos de la *psicología conductista*, donde el algoritmo aprende por sí mismo como debe operar en función de un sistema de penalizaciones y recompensas. La implementación de un algoritmo RL precisa de una gran cantidad de iteraciones de acciones tanto de tipo aleatorias (exploración) como valiosas a nivel de recompensa (explotación), a modo de perfeccionar las funciones de comportamiento del algoritmo.

3.4.4. Selección del modelo a utilizar

Las bases de datos EEG utilizadas en esta investigación incluyen etiquetas en segmentos identificados como *crisis* y *no-crisis* epiléptica. Como se busca discriminar

unicamente entre estas dos clases, es conveniente abordar el problema con clasificadores binarios. Por otra parte, el pre-etiquetado de las señales facilita la implementación de los algoritmos SL. Si bien los algoritmos DL son también buenos candidatos para realizar la tarea, sus elevados requerimientos los relegan a problemas con múltiples clases de datos o en los cuales se tiene desconocimiento de estas. Debido al interés por clasificar los datos con el mayor nivel de precisión posible y teniendo en cuenta los excelentes resultados alcanzados en la bibliografía por las Máquinas de Vectores de Soporte, se ha seleccionado este modelo para realizar la clasificación.

3.4.5. Máquina de vectores de soporte

Una Máquina de Vectores de Soporte es un algoritmo de clasificación binaria supervisada, desarrollado en 1995 por Vladimir Vapnik y su equipo en los laboratorios AT&T. El SVM se entrena a partir de conjuntos de dos clases de características etiquetadas, definiendo un hiperplano de separación entre los puntos de cada clase [35]. SVM realiza la clasificación determinando de qué lado del hiperplano se sitúan los datos de un nuevo conjunto de características. Dado que existe un número infinito de hiperplanos posibles que realicen la separación, el algoritmo SVM busca el hiperplano de margen máximo entre los datos de cada clase. El algoritmo SVM se define para tres casos detallados a continuación.

3.4.5.1. Caso separable linealmente

Sea un conjunto de entrenamiento $X \in \mathbb{R}^{m \times n}$ conformado por dos clases diferentes de datos, donde x_i es el i -ésimo vector del conjunto y x_{ij} es la j -ésima característica de dicho vector. La matriz X puede ser expresada como:

$$X = \begin{bmatrix} x_1^T \\ x_2^T \\ \vdots \\ x_m^T \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \dots & \vdots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix} \quad (3.29)$$

Dependiendo de la clase de cada vector x_i , se asigna una etiqueta y_i que toma valores 1 ó -1, construyéndose un vector de etiquetas $Y \in \{-1, 1\}$ dado por:

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{bmatrix} \quad (3.30)$$

Se tiene un plano en \mathbb{R}^d en el que cada eje representa una característica. Si los vectores x_i , expresados como puntos rojos y azules en la Figura (3.3), pueden separarse por dos hiperplanos H_1 y H_2 , tal que el margen entre estos es máximo, entonces existe un hiperplano óptimo $H \in \mathbb{R}^d$ que divide las dos clases y el conjunto X es *separable linealmente*.

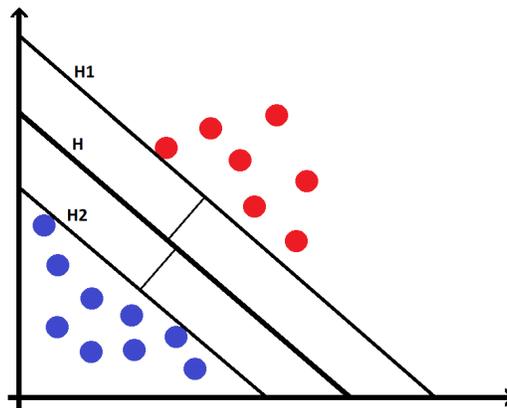


Figura 3.3 – Ejemplo de hiperplanos separadores para el caso separable linealmente.

El hiperplano de separación H es definido como una función lineal de la forma:

$$H = w_1x_1 + \dots + w_dx_d + b = (w^\top \cdot x_i + b) = 0, \quad (3.31)$$

donde $w^\top \in \mathbb{R}^d$ es el vector de peso y $b \in \mathbb{R}$ es el coeficiente de parcialidad. El hiperplano H debe satisfacer las siguientes restricciones para todos los conjuntos de

datos:

$$\begin{aligned} (w^\top \cdot x_i + b) &\geq 0, & \text{si } y_i = +1 \\ (w^\top \cdot x_i + b) &\leq 0, & \text{si } y_i = -1 \end{aligned} \quad (3.32)$$

Los hiperplanos H_1 y H_2 son expresados como:

$$\begin{aligned} H_1 &= (w^\top \cdot x_i + b) = +1 \\ H_2 &= (w^\top \cdot x_i + b) = -1 \end{aligned} \quad (3.33)$$

Las restricciones de clase de (3.32) pueden ser generalizadas para los hiperplanos H_1 y H_2 en una única restricción multiplicada por los valores $\{-1,1\}$ de Y , de modo que:

$$y_i(w^\top \cdot x_i + b) - 1 \geq 0, \quad \forall i \quad (3.34)$$

Si se denota como x_+ y x_- al par de vectores de cada clase más próximos al hiperplano separador, la distancia total entre estos vectores respecto a H se determina mediante:

$$d = \frac{|(w^\top \cdot x_+ + b) - (w^\top \cdot x_- + b)|}{\sqrt{w_1^2 + w_2^2 + \dots + w_d^2}} \quad (3.35)$$

Despejando las ecuaciones H_1 y H_2 de (3.33) y reemplazando en (3.35) se obtiene:

$$d = \frac{(1 - b) + (1 + b)}{\|w\|_2} = \frac{2}{\|w\|_2} = \frac{2}{w^\top \cdot w} \quad (3.36)$$

Como se busca maximizar el margen de separación entre los hiperplanos H_1 y H_2 , la distancia entre estos se representa como un problema de optimización con la restricción de (3.34), dado por:

$$\begin{aligned} &\underset{w,b}{\text{máx}} && \frac{2}{w^\top \cdot w} \\ \text{s.a} &&& y_i(w^\top \cdot x_i + b) - 1 \geq 0 \end{aligned} \quad (3.37)$$

El problema de maximización de (3.37) puede ser expresado como un problema de minimización, tal que:

$$\begin{aligned} \min_{w,b} \quad & \frac{1}{2} (w^\top \cdot w) \\ \text{s.a} \quad & y_i(w^\top \cdot x_i + b) - 1 \geq 0 \end{aligned} \quad (3.38)$$

La expresión (3.38) corresponde a un problema de Programación Cuadrática (QP) y se puede resolver utilizando *multiplicadores de Lagrange*¹, denotados por α_i . El problema de minimización se representa como una función Lagrangiana definida por:

$$\mathcal{L}_P(w, b, \alpha) = \frac{1}{2} (w^\top \cdot w) - \sum_{i=1}^n \alpha_i [y_i(w^\top \cdot (x_i + b) - 1)] \quad (3.39)$$

Resolver directamente el Lagrangiano de (3.39) es complejo dado que se encuentra en función de las variables w , b y α . Este problema se conoce como problema *primal* y puede ser convertido a un problema *dual* de maximización aplicando las condiciones de Karush-Kuhn-Tucker (KKT) dadas por:

$$\begin{aligned} \frac{\partial \mathcal{L}_P(w, b, \alpha)}{\partial w} = 0 & \longrightarrow w = \sum_{i=1}^n \alpha_i y_i x_i \\ \frac{\partial \mathcal{L}_P(w, b, \alpha)}{\partial b} = 0 & \longrightarrow \sum_{i=1}^n \alpha_i y_i = 0 \\ \alpha_i [y_i(w^\top \cdot x_i + b) - 1] & = 0 \\ y_i(w^\top \cdot x_i + b) - 1 & \geq 0 \\ \alpha_i & \geq 0 \end{aligned} \quad (3.40)$$

Reemplazando las condiciones KKT de (3.40) en la expresión del Lagrangiano de (3.39) y resolviendo, se obtiene un problema dual únicamente en función de los

¹El término preciso es *multiplicadores de Karush-Kuhn-Tucker* dado que existen restricciones de desigualdad, sin embargo, por consenso bibliográfico, se utiliza *multiplicadores de Lagrange*.

multiplicadores de Lagrange α_i , expresado por:

$$\mathcal{L}_D(\alpha) = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i y_i (x_i^\top \cdot x_j) y_j \alpha_j + \sum_{i=1}^n \alpha_i \quad (3.41)$$

Resulta conveniente resolver los problemas SVM a través de la forma dual ya que la función no depende de la dimensionalidad del espacio de características sino de la cardinalidad del conjunto de entradas. Si se convierte el problema de maximización al problema de minimización, de modo tal que $\max_a \mathcal{L}_D = \min_a -\mathcal{L}_D$, se obtiene:

$$\begin{aligned} \min_a \quad & \frac{1}{2} \alpha^\top Q \alpha - 1^\top \alpha \\ \text{s.a} \quad & Y^\top \cdot \alpha = 0 \\ & \alpha_i \geq 0 \end{aligned} \quad (3.42)$$

donde α es el vector de *multiplicadores de Lagrange* y Q la matriz dada por:

$$Q_{ij} = y_i (x_i^\top \cdot x_j) y_j \quad (3.43)$$

Calculando los multiplicadores de Lagrange, los vectores del conjunto de entrenamiento que se encuentran sobre H_1 y H_2 , asociados a un multiplicador de Lagrange $\alpha_i > 0$ se denominan *vectores de soporte* y se denotan por *vs*. Una vez obtenidos, se reemplazan en la condición KKT del vector de peso w dada por:

$$w = \sum_{i=1}^n \alpha_i y_i x_i \quad (3.44)$$

El coeficiente de parcialidad b se obtiene reemplazando w en la restricción de la ecuación (3.34) y luego promediando los valores de b obtenidos de calcular la ecuación para los vectores de *vs*:

$$b = \frac{1}{N_{vs}} \sum_{i=vs}^n (y_i - w^\top \cdot x_i) \quad (3.45)$$

Una vez calculados los parámetros w y b del clasificador, se reemplazan en la expresión del hiperplano H de (3.31), obteniéndose la función de clasificación:

$$y_k = \text{signo}(w^\top \cdot x_k + b) \quad (3.46)$$

donde y_k es el signo del valor obtenido de calcular la expresión (3.46) para un nuevo vector x_k de clase desconocida. La clase a la cual pertenece el nuevo vector se determina en función de si el signo obtenido en el cálculo de y_k es negativo o positivo, ubicándose el vector en uno de los dos lados del hiperplano óptimo.

3.4.5.2. Caso cuasi-separable linealmente

El caso separable linealmente es un modelo ideal del SVM debido a que en los ejemplos de la realidad es difícil encontrar conjuntos de datos que puedan separarse completamente. Por otro lado, el modelo no puede ser generalizado para nuevos conjuntos de datos, condición conocida como *sobreaajuste*. Para proporcionar cierta flexibilidad al SVM se estima un parámetro de penalización que compensa los errores de entrenamiento y de margen, dando origen a un modelo de *margen blando*, el cual permite que algunos de los vectores de entrenamiento no verifiquen las restricciones asociadas al problema primal. Este caso se denomina *cuasi-separable linealmente* y es ilustrado en la Figura (3.4). Por medio del uso de un conjunto de *variables de holgura* $\xi_i \in \mathbb{R}^+$, con $i = 1, \dots, n$, asociadas cada vector de entrenamiento, es posible controlar la cantidad de vectores no separables. Luego, la restricción (3.34) se puede reescribir como:

$$y_i(w^\top \cdot x_i + b) \geq 1 - \xi_i \quad i = 1, \dots, n \quad (3.47)$$

La clasificación de vectores en función de la *variable de holgura* ahora puede originar tres casos distintos. Si para un vector x_i se cumple que $\xi_i = 0$, entonces se dice que el vector es separable. Si se cumple que $0 < \xi_i < 1$, el vector no es separable pero se encuentra correctamente clasificado. En caso de que $\xi_i > 1$, el vector no es separable y se encuentra mal clasificado. La sumatoria de los valores ξ_i permite cuantificar la penalización asociada a la inclusión de vectores no-separables.

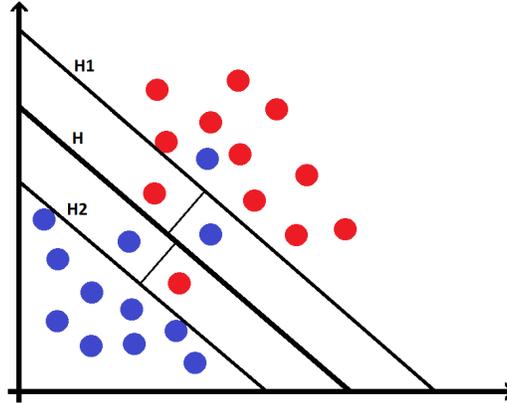


Figura 3.4 – Ejemplo de hiperplanos separadores para el caso cuasi-separable linealmente.

La función de optimización de (3.38) ahora tiene la forma:

$$\begin{aligned} \min_{w,b} \quad & \frac{1}{2} (w^\top \cdot w) + C \sum_{i=1}^n \xi_i \\ \text{s.a.} \quad & y_i (w^\top \cdot x_i + b) - 1 + \xi_i \geq 0 \\ & \xi_i \geq 0 \end{aligned} \quad (3.48)$$

donde C es el parámetro de penalización. La función Lagrangiana tiene la forma:

$$\mathcal{L}_P(w, b, \alpha, \mu, \xi) = \frac{1}{2} (w^\top \cdot w) + C \sum_{i=1}^n \xi_i - \sum_{i=1}^n \alpha_i [y_i (w^\top \cdot x_i + b) - 1 + \xi_i] - \mu_i \xi_i \quad (3.49)$$

la resolución del problema primal por las condiciones de KKT está dada por:

$$\begin{aligned} \frac{\partial \mathcal{L}_P(w, b, \alpha, \mu, \xi)}{\partial w} = 0 & \longrightarrow w = \sum_{i=1}^n \alpha_i y_i x_i \\ \frac{\partial \mathcal{L}_P(w, b, \alpha, \mu, \xi)}{\partial b} = 0 & \longrightarrow \sum_{i=1}^n \alpha_i y_i = 0 \\ \frac{\partial \mathcal{L}_P(w, b, \alpha, \mu, \xi)}{\partial \xi_i} = 0 & \longrightarrow C - \alpha_i - \mu_i = 0 \end{aligned} \quad (3.50)$$

$$\begin{aligned}
\alpha_i [y_i(w^\top \cdot x_i + b) - 1 + \xi_i] &= 0 \\
\mu_i \xi_i &= 0 \\
y_i(w^\top \cdot x_i + b) - 1 + \xi_i &\geq 0 \\
\xi_i, \alpha_i, \mu_i &\geq 0
\end{aligned} \tag{3.51}$$

Reemplazando las expresiones de (3.50) en (3.49) se obtiene la expresión del problema dual del caso cuasi-separable linealmente:

$$\mathcal{L}_D(\alpha) = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i y_i (x_i^\top \cdot x_j) y_j \alpha_j + \sum_{i=1}^n \alpha_i \tag{3.52}$$

el cual a su vez puede ser cambiado de maximización a minimización como:

$$\begin{aligned}
\min_a \quad & \frac{1}{2} \alpha^\top Q \alpha - 1^\top \alpha \\
s.a \quad & Y^\top \cdot \alpha = 0 \\
& 0 \leq \alpha_i \leq C
\end{aligned} \tag{3.53}$$

El problema de optimización del caso cuasi-separable linealmente es similar al caso separable linealmente, salvo por la cota superior C de la restricción de los multiplicadores de Lagrange, la cual se deduce a partir de las condiciones complementarias de (3.51). Para construir la función de clasificación, el valor de w se deduce de la primera condición KKT de (3.50) y b puede obtenerse aplicando las condiciones complementarias y promediando los valores calculados para cada vector de soporte.

3.4.5.3. Caso no separable linealmente

Si se contempla el uso de SVM para casos en los que los conjuntos de datos tienen más de dos características, presentan curvas de separación no lineales, no pueden ser separados completamente o se busca clasificar en más de dos categorías, entonces es necesario recurrir a la representación por medio de funciones Kernel (núcleo). Las

funciones kernel mapean el conjunto de datos $x_i \in X$ a un espacio de Hilbert de dimensión mayor F de modo tal que $\Phi : X \rightarrow F$ es la función de transformación, donde $\Phi(x) = [\phi_1(x), \dots, \phi_m(x)]$, $\exists \phi_i(x)$, $i = 1, \dots, m$, y $\phi_i(x)$ es una función no lineal. Una función kernel asigna a cada vector del espacio de entradas, un valor real en el espacio de características dado por:

$$K(x_i, x_j) = (\phi(x_i) \cdot \phi(x_j)) = \phi_1(x_i)\phi_1(x_j) + \dots + \phi_m(x_i)\phi_m(x_j)$$

La función kernel está representada por el producto escalar $(\phi(x_i) \cdot \phi(x_j))$. Las funciones kernel más comunmente utilizadas son:

- Kernel perceptron:

$$K(x_i, x_j) = \|x_i - x_j\|$$

- Kernel polinómico de grado- p :

$$K(x_i, x_j) = [\gamma(x_i \cdot x_j) + \tau]^p$$

- Kernel gaussiano:

$$K(x_i, x_j) = e^{-\gamma\|x_i - x_j\|^2}, \quad \gamma > 0$$

- Kernel sigmoidal:

$$K(x_i, x_j) = \tanh(\gamma(x_i \cdot x_j) + \tau)$$

Los parámetros γ , τ , p , se denominan parámetros del kernel y se escogen manualmente. Las distintas combinaciones entre estos valores determinan los resultados de precisión en la clasificación de las características. Considerando la forma dual del Lagrangiano del problema cuasi-separable linealmente:

$$\begin{aligned} \min_{\alpha} \quad & \frac{1}{2} \alpha^\top Q \alpha - 1^\top \alpha \\ \text{s.a} \quad & Y^\top \cdot \alpha = 0 \\ & 0 \leq \alpha_i \leq C \end{aligned} \tag{3.54}$$

la matriz Q se expresa sustituyendo la función kernel en el producto escalar, tal que:

$$Q_{ij} = y_i K(x_i, x_j) y_j \quad (3.55)$$

Utilizando los multiplicadores de Lagrange α calculados para el modelo cuasi-separable linealmente, la expresión del hiperplano separador construido sobre en el espacio de características está dada por:

$$w_k = \sum_{i=1}^n \alpha_i^* y_i K(x_i, x_j) \quad (3.56)$$

donde α_i^* corresponde a los multiplicadores de Lagrange asociados a los vectores de soporte calculados para el problema dual. En general, muchos de los modelos SVM operan sobre conjuntos no linealmente separables, por lo que se recurre al uso de funciones kernel no lineales para ampliar la dimensionalidad del espacio de características y determinar el hiperplano de separación óptimo en dicho espacio.

3.5. Procesamiento de señales EEG en MATLAB

Las señales EEG usadas en esta investigación se registraron en Formato de Datos Europeo (EDF). El formato EDF permite almacenar distintos tipos de señales biomédicas y registrar eventos y anotaciones. El archivo EDF se compone inicialmente de una cabecera con información sobre la grabación y posteriormente del registro multicanal ininterrumpido de la señal EEG [36]. La cabecera se divide en dos secciones; la primera presenta información general sobre el paciente y características de la grabación y la segunda proporciona información sobre las señales almacenadas en cada canal. En el software MATLAB, se accede al archivo EDF utilizando el comando “`edfread()`”. Para desplegar la cabecera de datos en *command window* se utiliza la instrucción “`edfinfo()`”. Las tablas (3.1) y (3.2) indican los datos que presenta el registro EDF en las secciones primera y segunda de la cabecera, respectivamente. El resto del archivo EDF corresponde a los registros de señales almacenados en formato “`timetable`” conformado por arreglos de vectores de celdas.

Tabla 3.1 – Sección de información general de cabecera de archivo EDF

Nombre	Función
Filename	Nombre del archivo EDF
FileModDate	Fecha de última modificación de archivo EDF
FileSize	Tamaño del archivo en Bytes
Version	Versión del formato de datos
Patient	Detalles de identificación del paciente
Recording	Detalles de identificación de la grabación
StartDate	Fecha de inicio de grabación
StartTime	Hora de inicio de grabación.
HeaderBytes	Tamaño de cabecera en Bytes
Reserved	Continuidad o discontinuidad de la grabación
NumDataRecords	Número de grabaciones de datos en el archivo
DataRecordDuration	Duración de cada grabación de dato.
NumSignals	Número de señales en el archivo

Tabla 3.2 – Sección de información de señales de cabecera de archivo EDF

Nombre	Función
SignalLabels	Nombres de las señales
TransducerTypes	Detalles sobre transductores
PhysicalDimensions	Unidad de medida física de las señales
PhysicalMin	Valor mínimo de la señal física
PhysycalMax	Valor máximo de la señal física
DigitalMin	Valor mínimo de la señal digital
DigitalMax	Valor máximo de la señal digital
NumSamples	Número de muestras de señal
Prefilter	Datos de prefiltros de señales
SignalReserved	Información adicional de señal
Annotations	Anotaciones presentes en señales grabadas

3.6. Conclusión del capítulo

El Marco Teórico presentado en este capítulo esclareció de forma analítica las técnicas de procesamiento utilizadas en la investigación. A lo largo del capítulo 4, titulado Experimentación y Resultados, se ilustrarán los resultados particulares de la aplicación de cada una de estas técnicas sobre las señales EEG así como los resultados de su implementación en conjunto en el algoritmo objeto de este trabajo.

CAPÍTULO 4

Experimentación y Resultados

4.1. Análisis de señales EEG

Expuestos los antecedentes y el marco teórico que justifican este trabajo, en las próximas secciones se presentan los resultados de la aplicación experimental de la metodología propuesta. Las simulaciones se realizaron sobre las bases de datos descritas en el apartado 2.6, a través de *scripts* en el entorno MATLAB. Estos métodos pueden ser implementados tanto en el análisis de señales EEG para la detección de ataques de epilepsia como en el estudio de la actividad cerebral en general.

4.1.1. Revisión de bases de datos EEG en MATLAB

Las señales de las bases de datos EEG utilizadas fueron graficadas simultáneamente en MATLAB para representar la información contenida en los archivos EDF.

4.1.1.1. Base de datos UCIN Hospital Universitario de Helsinki

En la base de datos del Hospital Universitario de Helsinki, se configuró un montaje monopolar de 19 electrodos activos respecto a un electrodo de referencia en las ubicaciones sobre la corteza cerebral: Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1 y O2, además de dos canales para registros de electrocardiograma (ECG EKG) y esfuerzo respiratorio (Resp Effort) [20]. La Figura (4.1) muestra el conjunto de señales EEG contenidas en el archivo “`eeg34.edf`” en el intervalo de tiempo entre 1 y 600 segundos. Mediante inspección visual, presuntamente se aprecia una crisis epiléptica en el intervalo entre 1 y 452 segundos.

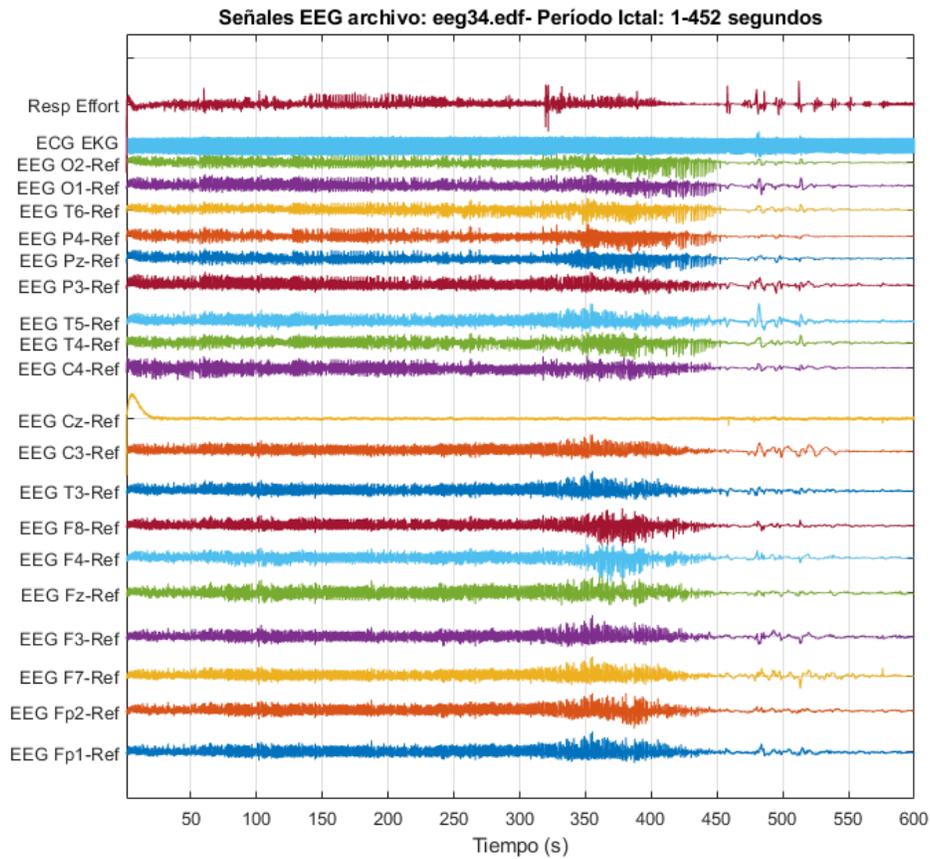


Figura 4.1 – Registro EDF con fase ictal. Paciente 34, base de datos Hospital de Helsinki.

La afirmación anterior puede ser corroborada con los archivos de anotaciones de las señales del conjunto, incluidos en la base de datos del Hospital Universitario de Helsinki denominados “`annotations_2017_A.csv`”, “`..._B.csv`” y “`..._C.csv`”. La gráfica de los archivos de anotaciones para el intervalo se muestra en la Figura (4.2).

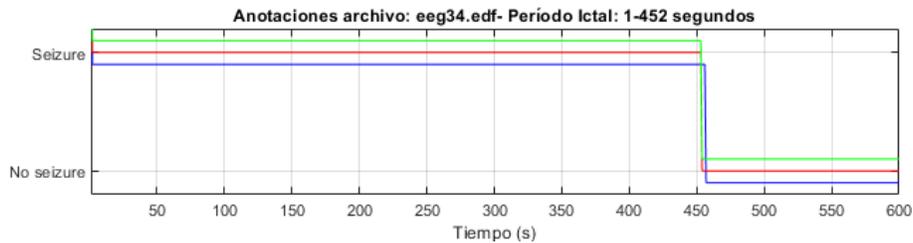


Figura 4.2 – Gráfica de anotaciones paciente 34. Base de datos Hospital de Helsinki.

4.1.1.2. Base de datos Hospital de Niños de Boston CHB-MIT

En la base de datos CHB-MIT se configuró un montaje bipolar de 23 canales en las ubicaciones de la corteza cerebral: T8-P8, FT10-T8, FT9-FT10, T7-FT9, P7-T7, CZ-PZ, FZ-CZ, P8-O2, T8-P8, F8-T8, FP2-F8, P4-O2, C4-P4, F4-C4, FP2-F4, P3-O1, C3-P3, F3-C3, FP1-F3, P7-O1, T7-P7, F7-T7, FP1-F7 [21]. La Figura (4.3) muestra el conjunto de señales EEG contenidas en el archivo “chb01_03.edf” en el intervalo de tiempo entre 2950 y 3150 segundos. La base de datos CHB-MIT contiene el archivo de texto “chb01-summary.txt”, con el registro de crisis epilépticas en grabaciones edf del paciente 01. Para la grabación 03, se indica un ataque epiléptico en el intervalo de tiempo entre 2996 y 3036 segundos, tal como se muestra en la Figura (4.3).

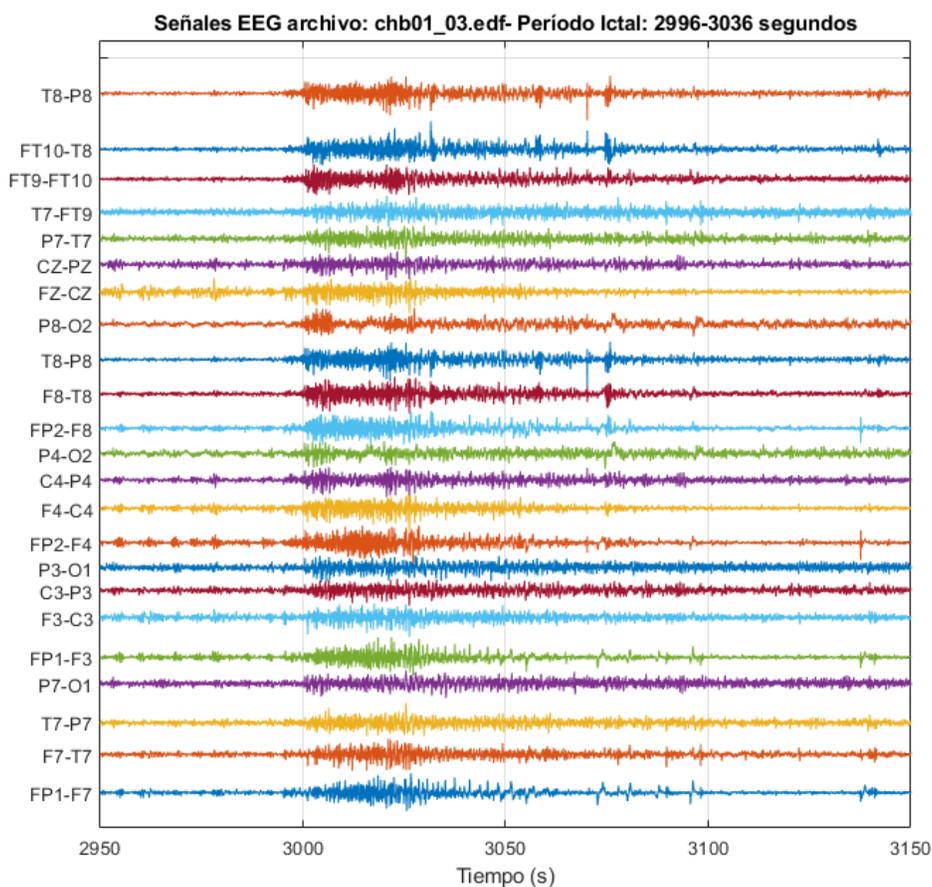


Figura 4.3 – Registro EDF con fase ictal. Paciente 01, grabación 03, base de datos CHB-MIT.

4.1.2. Consideraciones previas a los experimentos

Los experimentos descritos en las próximas secciones se implementaron utilizando la señal correspondiente al registro de un solo canal del conjunto de datos de cada archivo edf. Teniendo en cuenta que los conjuntos de datos del Hospital de Helsinki y CHB-MIT fueron adquiridos utilizando montajes distintos, monopolar y bipolar, respectivamente, y las ubicaciones de los electrodos y los grupos etarios de los pacientes (recién nacidos - niños y adolescentes) difirieron en cada caso, es que se consideró crear dos modelos de clasificación propios para cada base de datos.

4.2. Preprocesamiento de la señal EEG

El preprocesamiento de las señales EEG se realizó a través del filtro Savitzky-Golay. Los parámetros del filtro, orden y longitud de ventana óptimos fueron determinados llevando a cabo sucesivos filtrados sobre una señal contaminada con distintos niveles de potencia de Ruido Gaussiano Blanco (WGN) y comparando los resultados.

4.2.1. Adición de Ruido Gaussiano Blanco a señales

Seleccionando la señal de prueba 5 del archivo “chb01_03.edf”, se le añadió un vector fila de la misma longitud de la señal con valor constante cero, mediante la función “zeros()”. Se generó ruido gaussiano blanco sobre la señal de prueba con la extensión, utilizando la función “awgn()” para niveles SNR de -15, -10, -5, 0, 5, 10 y 15 dB. A continuación, se extrajeron únicamente los vectores extensión con ruido añadido y se sumaron cada uno a la señal de prueba, dando lugar a siete nuevas señales contaminadas de ruido. En la Figura (4.4) se ilustra gráficamente la comparación entre una señal de prueba (Figura 4.4a) y la misma señal con adición de ruido gaussiano blanco de 0 dB (Figura 4.4b) y de -10dB (Figura 4.4c). Se calcularon los valores de potencia de cada vector de ruido P_n y la potencia de la señal de prueba P_s . Mediante la expresión:

$$SNR_{dB} = 10 \log \frac{P_s}{P_n} \quad (4.1)$$

se determinaron los valores de SNR respecto de la señal de entrada.

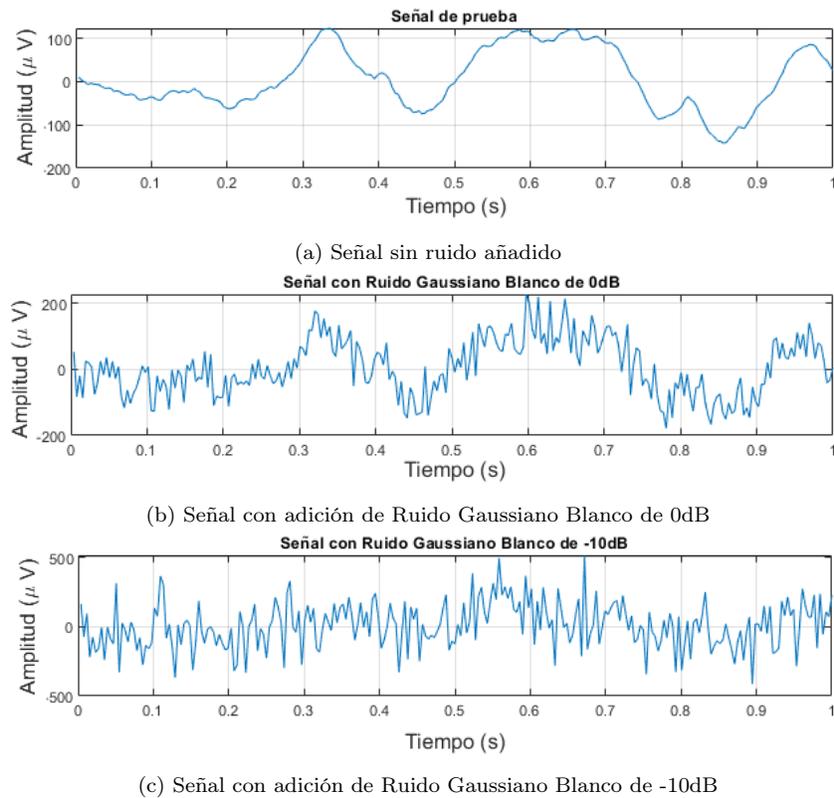


Figura 4.4 – Comparación de señal de prueba y señales con Ruido Gaussiano Blanco.

4.2.2. Elección de parámetros de filtro Savitzky-Golay

Debido a que existe un sinnúmero de posibles combinaciones de parámetros del filtro S-G, se consideraron todas las combinaciones para longitudes de ventana entre 3 y 41. Los criterios usados para la elección de los parámetros óptimos fueron:

1. **SNR:** se calculó el SNR de salida de las señales ruidosas filtradas y se seleccionaron los parámetros que produjeran un aumento del SNR hasta mínimo -3dB para señales con -15dB de ruido añadido.
2. **Correlación:** se calcularon los valores de correlación entre las señales de salida y la señal de prueba, seleccionando los parámetros con valores más altos.

De los experimentos, se establecieron como las mejores combinaciones: 16-27, 22-35, 20-33, 12-21 y 14-23, siendo seleccionada como óptima la combinación de orden

22 y longitud de ventana 35. En la Tabla 4.1 se realiza una comparación entre el SNR de entrada de la señal de prueba y el SNR de salida de filtros S-G con las combinaciones; 22-35, 5-15, 13-31, 24-25 y 3-27. En la Tabla 4.2 se muestran los valores de correlación entre la señal de prueba y las señales de los filtros para cada caso. Se concluyó experimentalmente que las combinaciones en donde el orden del filtro fue muy pequeño en comparación a la longitud de ventana (ejemplo: 3-27) presentaron buenos niveles de correlación a costa de un bajo aumento del SNR de salida. Al mismo tiempo, combinaciones en las cuales el orden de filtro fue cercano a la longitud de ventana (ejemplo: 24-25) presentaron un buen aumento del SNR de salida a costa bajos niveles de correlación.

Tabla 4.1 – Comparación entre SNR de entrada y SNR de salida de filtros S-G.

Potencia de Ruido generado [dB]	15	10	5	0	-5	-10	-15
SNR de Entrada	17.9858	12.9844	8.0216	2.9866	-1.9293	-7.0350	-12.0083
SNR S-G Or: 22, Fl: 35	17.9658	13.0130	8.2874	3.8992	0.4043	-1.7625	-2.8364
SNR S-G Or: 5, Fl: 15	17.7882	12.7990	7.9796	3.3234	-0.7473	-3.6284	-5.2986
SNR S-G Or: 13, Fl: 31	17.8540	12.8729	8.0722	3.4722	-0.4648	-3.1616	-4.6366
SNR S-G Or: 24, Fl: 25	18.0390	13.1597	8.6423	4.7668	2.1277	0.7905	0.2359
SNR S-G Or: 3, Fl: 27	17.4912	12.4792	7.5861	2.7240	-1.8782	-5.7654	-8.8408

Tabla 4.2 – Índice de correlación entre señal de prueba y señales de salida de filtros S-G.

Potencia de Ruido generado [dB]	15	10	5	0	-5	-10	-15
Correlación S-G Or: 22, Fl: 35	0.9945	0.9867	0.9631	0.8982	0.7565	0.5455	0.3425
Correlación S-G Or: 5, Fl: 15	0.9931	0.9890	0.9764	0.9395	0.8462	0.6684	0.5506
Correlación S-G Or: 13, Fl: 31	0.9939	0.9891	0.9741	0.9310	0.8256	0.6367	0.4203
Correlación S-G Or: 24, Fl: 25	0.9922	0.9759	0.9292	0.8164	0.6229	0.4090	0.2431
Correlación S-G Or: 3, Fl: 27	0.9782	0.9767	0.9719	0.9573	0.9156	0.8115	0.6244

La Figura (4.5) compara gráficamente la curva de SNR de Entrada (rojo) y las curvas de los resultados de SNR de salida de los filtros indicados en la Tabla 4.1, incluido el filtro 22-35 (azul). La Figura (4.6) compara los espectrogramas generados con la función “`spectrogram()`” para la señal 5 (FP1-F3) del archivo “`chb01_03.edf`” en el intervalo de 2950-3150 segundos (Figura 4.3), con ruido añadido de 15dB (Figura 4.6a) y la misma señal preprocesada con un filtro S-G 22-35 (Figura 4.6b).

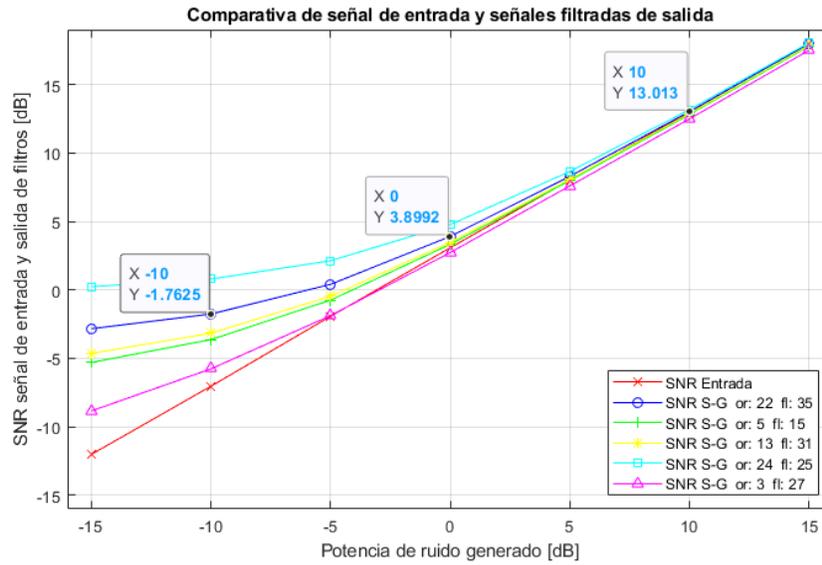


Figura 4.5 – Comparación entre SNR de señales de salida de filtros SG y SNR de entrada.

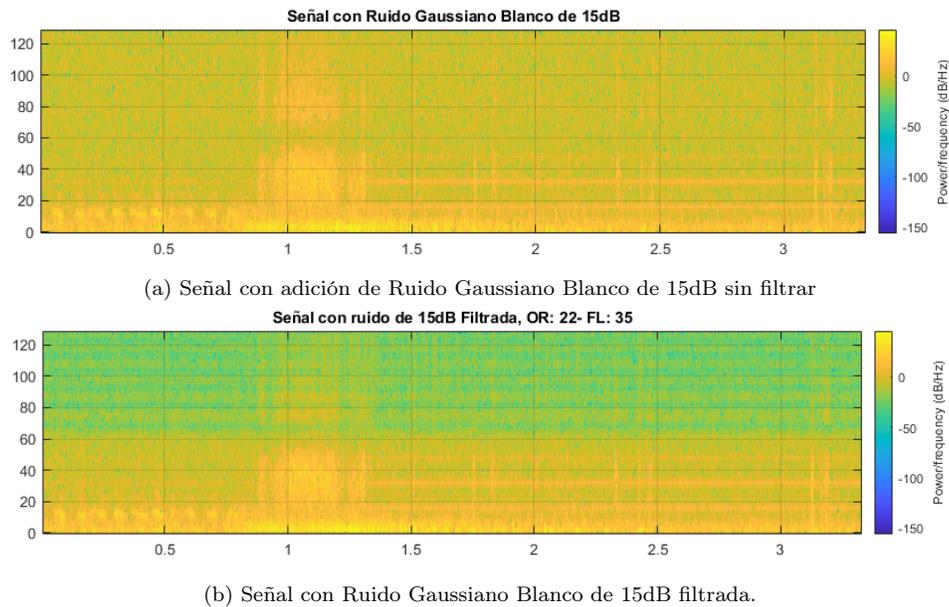


Figura 4.6 – Comparación entre espectrogramas de señal con ruido y señal con ruido filtrado

Cabe mencionar que el filtro S-G es un filtro de tipo paso-bajo, por lo que tiene una frecuencia de corte, la cual para este caso alcanzó un valor estimado de 60 Hz.

Emplear filtros con bajo orden y alta longitud de ventana (ejemplo: 3-27) disminuye la frecuencia de corte del filtro, sin embargo, también altera la señal en bajas frecuencias, produciendo pérdidas de información importante en los ritmos *alpha* y *beta*, a utilizar en las secciones siguientes del estudio.

4.2.3. Aplicación de Filtrado Savitzky-Golay

La señal de prueba fue preprocesada por medio del filtro Savitzky Golay con los parámetros orden: 22 y longitud de ventana: 35. La Figura 4.7 compara la señal de prueba (Figura 4.7a) con la señal de salida del filtro S-G (Figura 4.7b) durante un episodio epiléptico, donde se observa una notable reducción de la amplitud en las crestas de alta frecuencia.

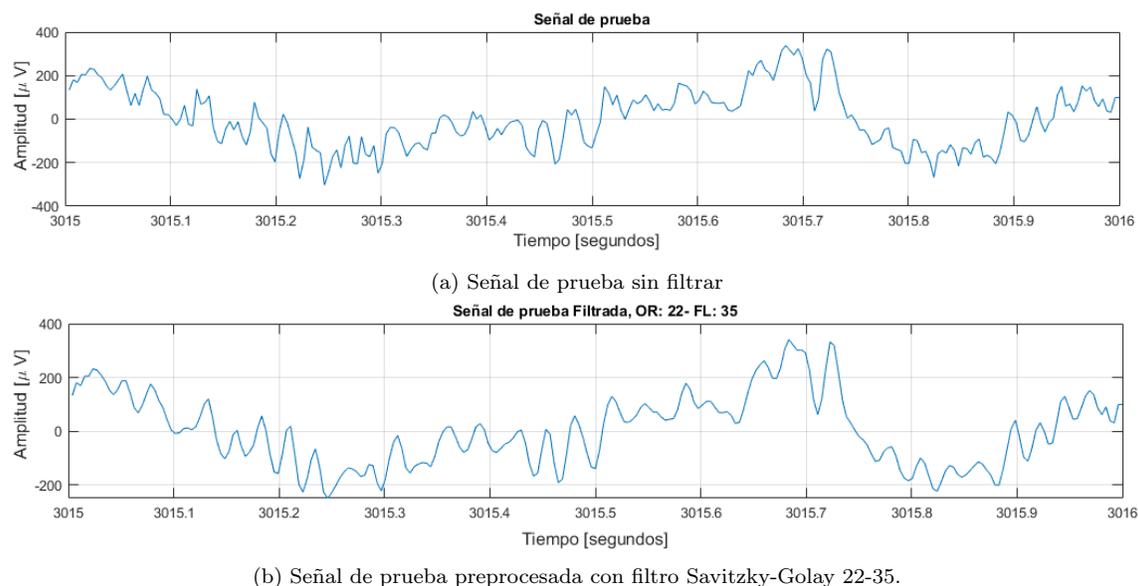


Figura 4.7 – Comparación entre segmentos de señal de prueba y señal filtrada.

El valor índice de correlación entre ambas señales alcanzado fue de 0.98181, indicando una alta correspondencia entre la señal de prueba y la señal filtrada. Lo anterior garantiza un buen prefiltrado así como una mínima pérdida de información en la salida del filtro. Una vez prefiltrada la señal, el paso siguiente llevado a cabo corresponde a la descomposición de la señal y la extracción de características.

4.3. Descomposición de la señal EEG

La aplicación de DWT consistió en hacer pasar la señal EEG por un banco de filtros como se describe en la sección 3.3.3.3. Se utilizó una frecuencia fundamental de 256Hz. La Figura (4.8) muestra el diagrama del modelo de descomposición de la señal EEG en coeficientes de aproximación y detalle.

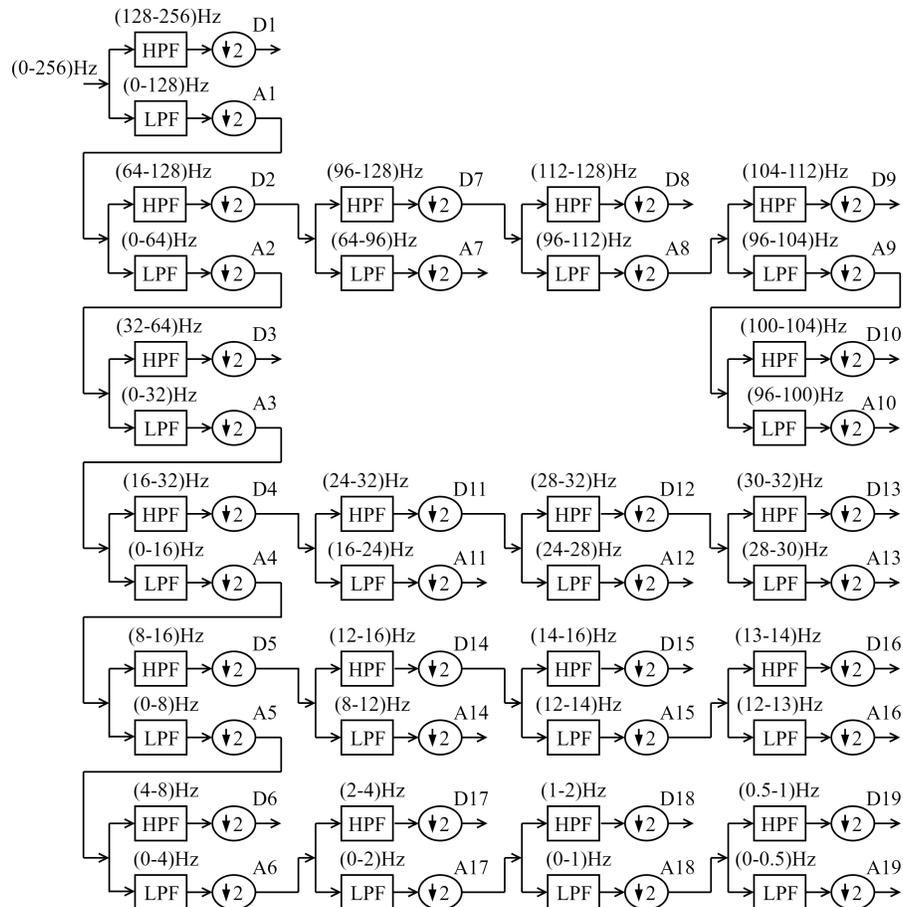


Figura 4.8 – Descomposición de señal EEG en coeficientes de aproximación y detalle.

A través de la interpolación y suma de coeficientes de aproximación y detalle se construyeron los coeficientes de los ritmos cerebrales espontáneos *delta*, *theta*, *alpha*, *beta* y *gamma*. Para componer el ritmo delta se utilizaron los coeficientes D17, D18 y D19. El ritmo theta se obtuvo directamente del coeficiente D6. El ritmo alpha

se construyó con los coeficientes A14 y A16. Para el ritmo beta se emplearon los coeficientes D16, D15, A11, A12 y A13. Por último, el ritmo gamma se constituyó a partir de los coeficientes D13, D3, A7 y A10. En la Figura (4.9) se muestra un intervalo de 15 segundos con las gráficas de coeficientes de los ritmos cerebrales espontáneos construidos utilizando Transformada Wavelet Discreta.

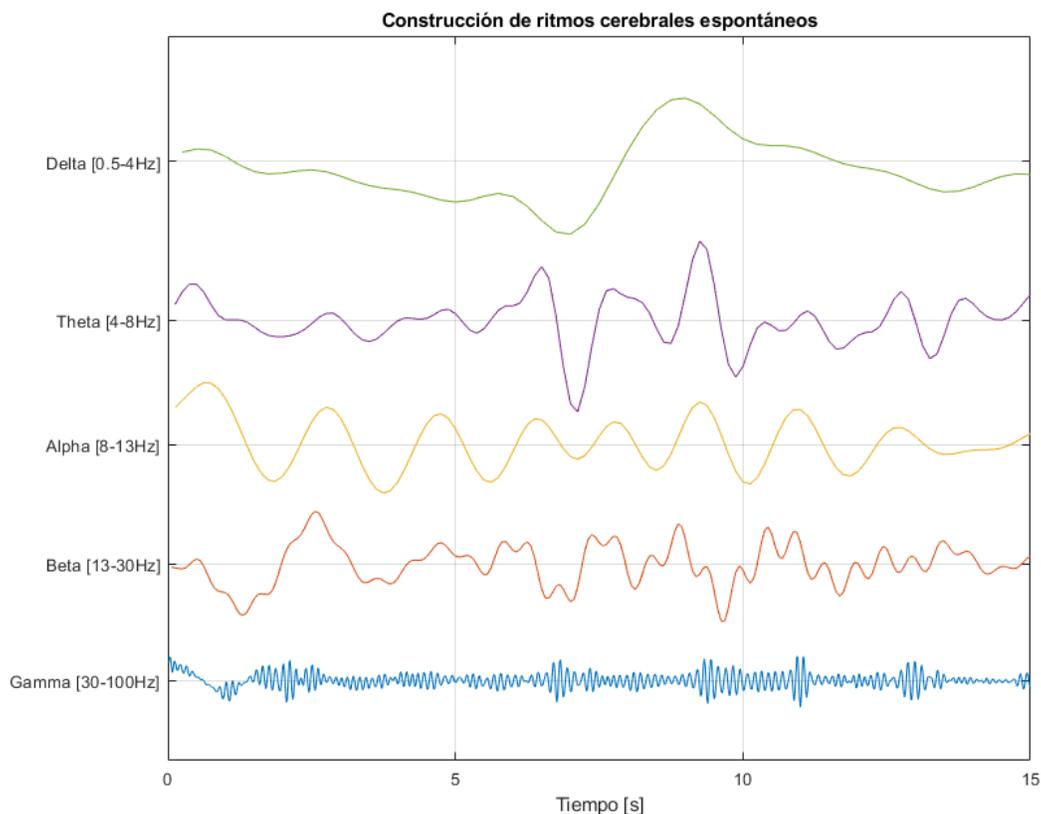


Figura 4.9 – Gráfica de construcción de ritmos cerebrales *delta*, *theta*, *alpha*, *beta* y *gamma*.

Los coeficientes utilizados para la implementación del algoritmo detector de ataques de epilepsia en señales EEG fueron los correspondientes al ritmo alpha y beta, ya que sus ondas se relacionan con el estado de relajación [7] y las funciones motoras [9], respectivamente. Se prescindió de los ritmos theta y delta debido a que solo se presentan con normalidad en infantes [11], así como del ritmo gamma, el cual está relacionado con funciones cerebrales cognitivas [19].

4.4. Extracción de características

Se seleccionaron intervalos de señal con presencia de ataques epilépticos y sin presencia de ellos. Para cada intervalo se calcularon las funciones *media*, *varianza*, *asimetría*, *curtosis*, *entropía de Shannon* y *energía*, descritas en la sección 4.4. Los cálculos fueron realizados sobre ventanas de muestras con períodos de 1 segundo y ventanas intermedias de muestras solapadas en medio segundo, o solapamiento de media ventana. Las Figuras (4.10) y (4.11) muestran las gráficas de características en el intervalo de 300 a 450 segundos del archivo eeg “chb01_21.edf”, calculadas para los ritmos cerebrales alpha y beta, respectivamente. En base a las anotaciones disponibles, se registra un ataque epiléptico entre los segundos 327 y 420, delimitado en las figuras por medio de líneas segmentadas negras.

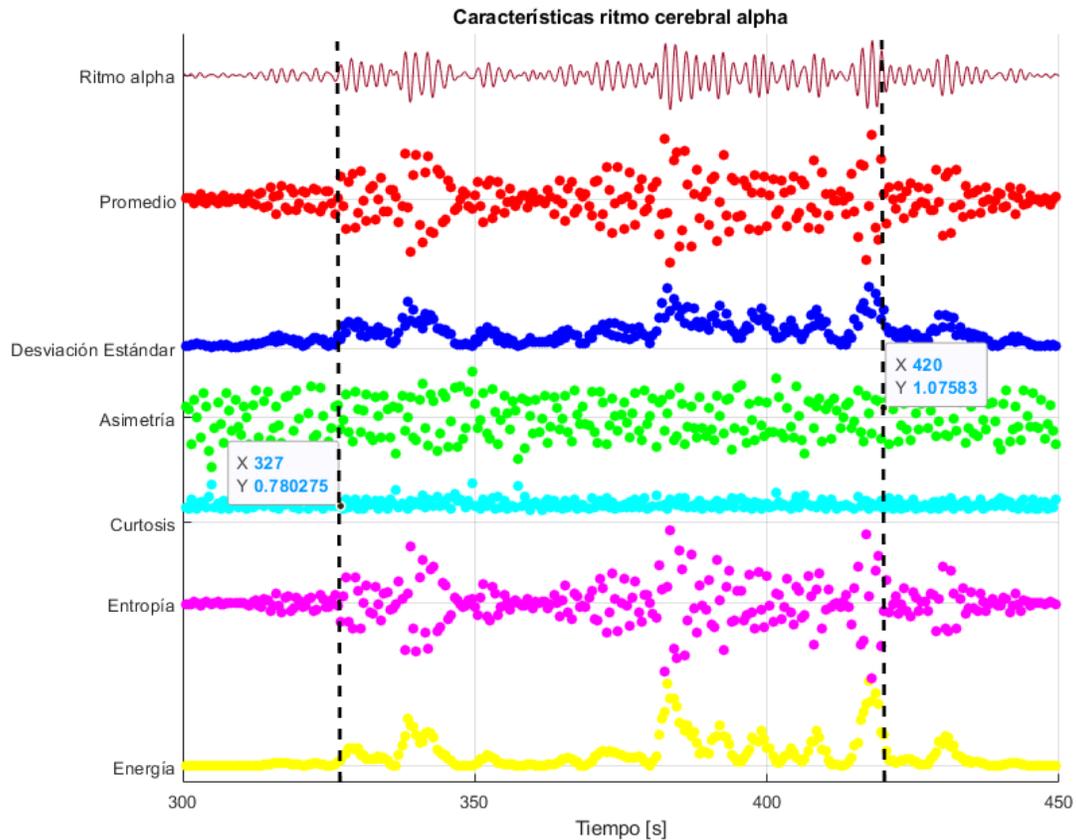


Figura 4.10 – Gráfica de características del ritmo cerebral alpha

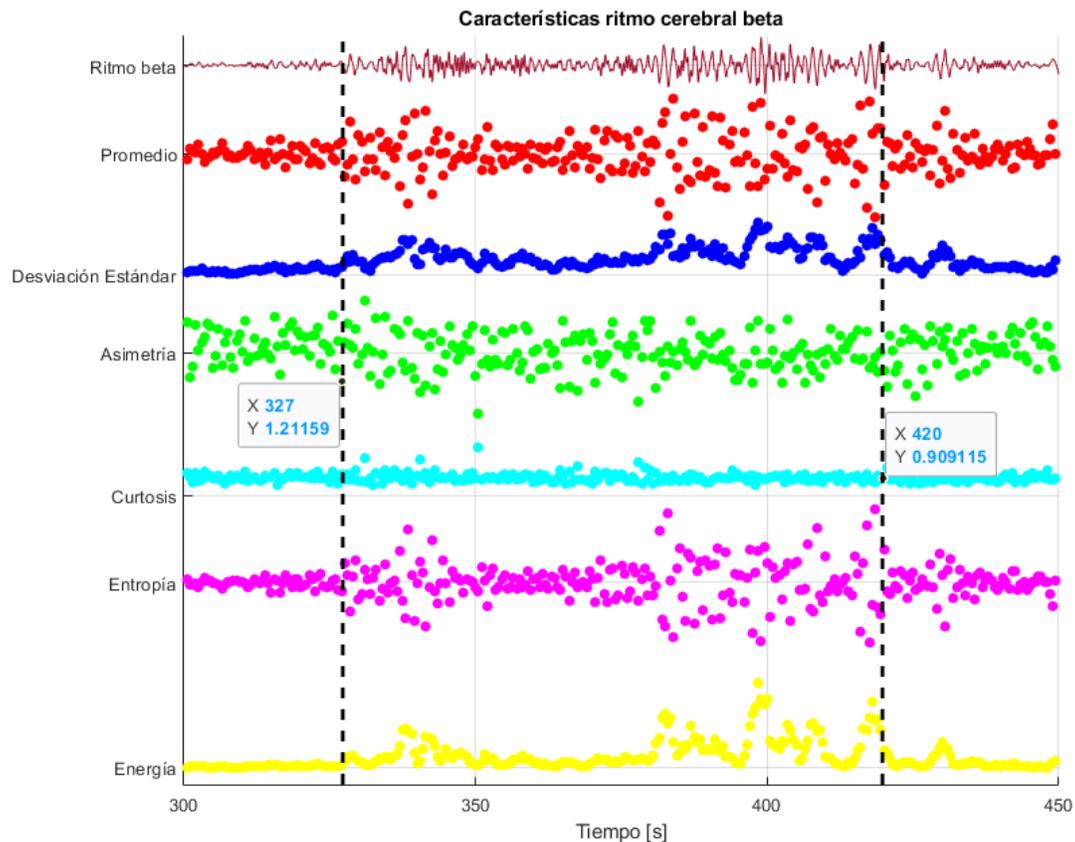


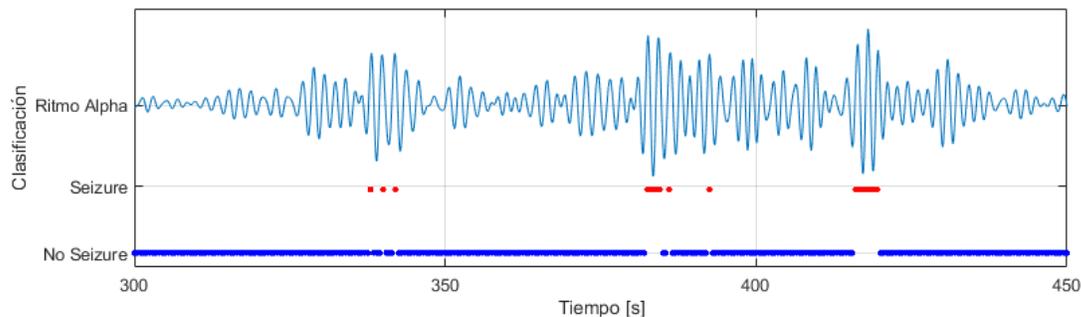
Figura 4.11 – Gráfica de características del ritmo cerebral beta

Obtenidos los vectores de características, se crearon conjuntos de entrenamiento con el 50% de vectores provenientes de intervalos con ataque epiléptico y el 50% de vectores de intervalos sin ataque. Los conjuntos se agruparon en *arreglos de estructuras* con el comando “`struct()`” y se almacenaron en archivos formato “.mat”. Se crearon arreglos de etiquetas para cada vector de características designando como “*seizure*” los ataques y como “*no-seizure*” los vectores sin crisis.

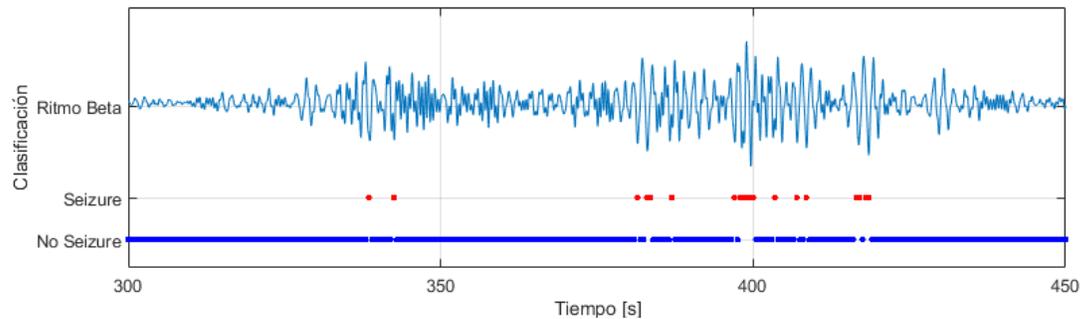
4.5. Entrenamiento de SVM y Clasificación de características

Determinados los conjuntos de características y sus etiquetas, se utilizaron como argumento para generar modelos SVM con kernel lineal para los ritmos alpha y beta por medio de la función “`fitcsvm()`”. Las clases de características en ambos casos se

distribuyeron de manera cuasi-separable linealmente. Se permitieron errores de clasificación en el modelo SVM para la clase *no-ataque* aplicando distintos parámetros de penalización C a través del comando “`cost`”. Los valores de C variaron en función de la cantidad de ejemplos de entrenamiento de cada experimento, así como la cantidad de ejemplos de cada clase. Se escogieron valores C de modo que, sometiendo sus respectivos modelos SVM a validación cruzada mediante la función “`crossval()`”, generasen entre 1 % y 5 % de pérdidas de clasificación sobre el total de ejemplos clasificados. Escoger valores de coeficientes C más altos disminuyó aún más la tasa de error, pero al mismo tiempo creó modelos SVM más ajustados (*overfitting*), siendo poco efectivos para realizar las detecciones. Se aplicaron los modelos SVM sobre los mismos datos de entrenamiento para constatar su funcionamiento. La Figura (4.12) muestra el resultado de la clasificación del conjunto de entrenamiento alpha (4.12a) y beta (4.12b) creado a partir de las características extraídas en la sección 4.4 para el intervalo 300 a 450 segundos de la señal “`chb01_21.edf`”.



(a) Resultado de entrenamiento y clasificación de ritmo alpha.



(b) Resultado de entrenamiento y clasificación de ritmo beta.

Figura 4.12 – Entrenamiento y clasificación de intervalo con crisis epiléptica.

En ambas figuras, los puntos rojos representan los segundos que fueron identificados como ataque epiléptico (*seizure*) y los puntos azules como no ataque (*no-seizure*). La clase de cada punto se determinó en base al signo positivo o negativo del cálculo del modelo SVM lineal sobre su vector de características respectivo. Los modelos SVM generados fueron almacenados en archivos formato “.mat”. Se crearon dos modelos SVM para las bases de datos CHB-MIT y Hospital Universitario de Helsinki, respectivamente y un tercer modelo SVM sobre la base de datos del Hospital de Helsinki sin realizar el prefiltrado Savitzky-Golay. Obtenidos los modelos SVM con kernel lineal, se llevaron a cabo las clasificaciones entre segmentos con y sin ataque epilépticos sobre las señales EEG de tres conjuntos de archivos EDF:

1. **Conjunto de prueba CHB-MIT:** se escogieron los primeros dos archivos EDF que presentaran crisis epilépticas de cada paciente del 1 al 10.
2. **Conjunto de prueba Hospital de Helsinki:** se escogieron los archivos EDF de los pacientes del 1 al 20. Algunos pacientes no presentaron crisis epilépticas.
3. **Conjunto de prueba Hospital de Helsinki sin prefiltrar:** Se utilizó el conjunto del punto 2 sin realizar el prefiltrado Savitzky-Golay sobre las señales.

El desempeño de la clasificación de los conjuntos de datos fue medido utilizando los indicadores *sensibilidad*, *especificidad* y *precisión*, definidos en la próxima sección.

4.6. Resultados y discusión

Debido a que las señales EEG presentan desbalances de datos de ataque epiléptico (menos) frente a datos de periodos sin ataque, se utilizaron los criterios de evaluación del clasificador, *sensibilidad* (Sen); porcentaje de ataques correctamente detectados, *especificidad* (Esp); número de veces que el algoritmo erró la clasificación del vector de datos, y *precisión* (Pre); combinación entre sensibilidad y especificidad. Estos criterios se expresan matemáticamente como;

$$Sensibilidad = \frac{TP}{TP + FN} * 100 \% \quad (4.2)$$

$$Especificidad = \frac{TN}{TN + FP} * 100 \% \quad (4.3)$$

$$Precisión = \frac{TP + TN}{TP + TN + FP + FN} * 100 \% \quad (4.4)$$

donde TP es el número de características clasificadas como verdaderos positivos, TN el número de verdaderos negativos, FP es el número de falsos positivos y FN el número de falsos negativos. Obtenidos los criterios de desempeño, se construyeron las tablas de resultados 4.3, 4.4 y 4.5, agrupadas por nombre del archivo EDF, número de señal clasificada, cantidad de ataques indicadas por los neurofisiólogos y criterios de desempeño calculados para las clasificaciones sobre los ritmos alpha y beta. Las señales utilizadas en cada caso fueron distintas para cada paciente y fueron las que mostraron mejor desempeño respecto del resto de señales de sus respectivos archivos EDF. Lo anterior sugiere que los ataques epilépticos se producen en sectores localizados del cerebro, resultando más fácil su detección en ciertos canales del electroencefalógrafo. La clasificación del conjunto de datos CHB-MIT alcanzó una media de precisión de 90.3 % para el ritmo alpha y 89.7 % para el ritmo beta, con valores de precisión por señal entre 50 % y 100 %, como se muestra en la tabla 4.3.

Tabla 4.3 – Resultados de clasificación de conjunto de datos CHB-MIT.

Archivo EDF	Señal	Ataques	Sen α	Sen β	Esp α	Esp β	Pre α	Pre β
chb01_03.edf	5	1	100	100	100	100	100	100
chb01_04.edf	22	1	100	100	100	100	100	100
chb02_16.edf	16	1	100	100	100	100	100	100
chb02_19.edf	5	1	100	100	50	50	66.7	66.7
chb03_01.edf	18	1	100	100	100	100	100	100
chb03_02.edf	18	1	100	100	100	100	100	100
chb04_05.edf	20	1	100	100	66.7	100	75	100
chb04_08.edf	14	1	100	100	100	100	100	100
chb05_06.edf	11	1	50	100	100	100	66.7	100
chb05_13.edf	18	1	100	100	100	50	100	66.7
chb06_01.edf	18	3	100	66.67	50	50	80	60
chb06_04.edf	11	2	100	100	100	100	100	100
chb07_12.edf	6	1	100	100	100	100	100	100
chb07_13.edf	15	1	100	100	100	100	100	100
chb08_02.edf	6	1	100	100	100	100	100	100
chb08_05.edf	20	1	100	100	100	100	100	100
chb09_06.edf	7	1	100	100	50	33.33	66.7	50
chb09_08.edf	23	2	100	100	100	100	100	100
chb10_12.edf	7	1	100	100	100	100	100	100
chb10_20.edf	10	1	100	100	0	0	50	50
Media	-	-	97.5	98.3	85.83	84.17	90.3	89.7

En la Figura (4.13) se comparan gráficamente los resultados de precisión alcanzada por el algoritmo sobre el conjunto de prueba CHB-MIT sobre los ritmos alpha y beta.

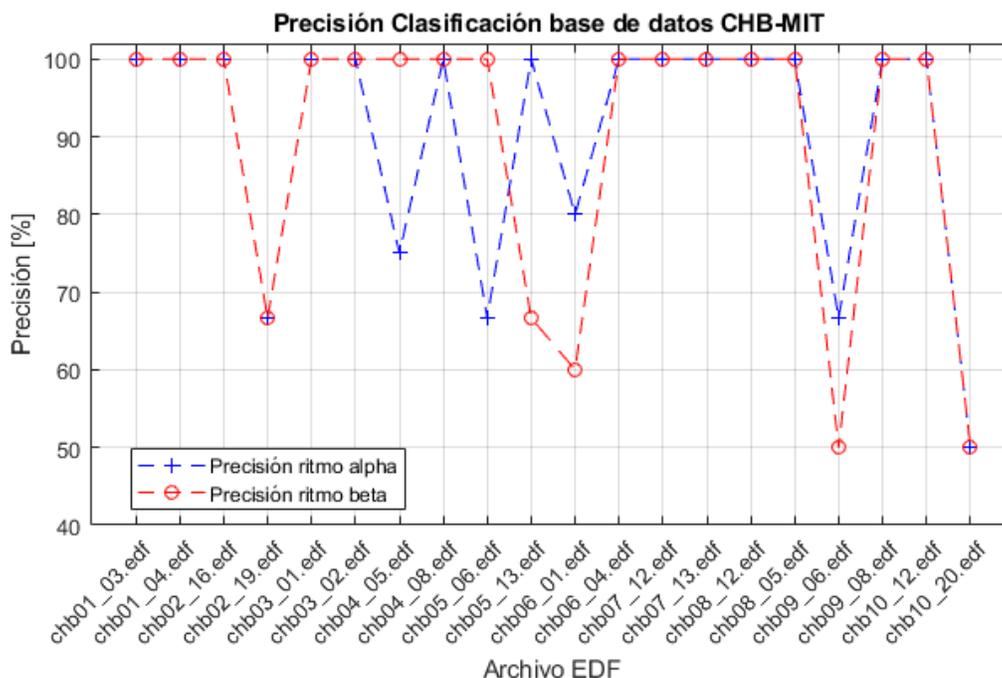


Figura 4.13 – Gráfica de precisión del clasificador para conjunto CHB-MIT

La clasificación de las características de alpha y beta alcanzó buenos niveles de precisión, constatando la importancia de ambos ritmos a la hora de realizar la detección de ataques epilépticos. Combinar los resultados de las detecciones en los dos ritmos permitió corroborar los resultados alcanzados en la clasificación de cada ritmo por sí solo. En el caso del conjunto de datos del Hospital de Helsinki, de la tabla 4.4, la media de precisión para el ritmo alpha fue de 93% y para el ritmo beta de 90.55%, con una variación de precisión por señal entre 57% y 100%. Para el caso del conjunto de datos del Hospital de Helsinki con modelo SVM sin filtrar de la tabla 4.5, los valores de precisión promedio alcanzados fueron de 73.35% y 70.13%, con valores de precisión por señal de entre 33.33% y 100%. Lo anterior evidencia una importante disminución en la capacidad del algoritmo para realizar las detecciones

si los datos utilizados para entrenar el modelo de decisión tanto como los datos para clasificar no son filtrados previamente.

Tabla 4.4 – Resultados de clasificación de conjunto de datos Hospital de Helsinki

Archivo EDF	Señal	Ataques	Sen α	Sen β	Esp α	Esp β	Pre α	Pre β
eeg1.edf	7	44	93.18	90.9	97.8	95.56	96	93.26
eeg2.edf	10	2	100	100	100	100	100	100
eeg3.edf	4	0	-	-	100	100	100	100
eeg4.edf	15	9	100	88.9	100	100	100	94.74
eeg5.edf	13	5	100	100	100	100	100	100
eeg6.edf	4	4	100	100	100	100	100	100
eeg7.edf	1	20	90	90	81	90.48	85	90.24
eeg8.edf	2	3	100	100	100	100	100	100
eeg9.edf	16	7	57.14	71.4	100	100	80	86.67
eeg10.edf	1	0	-	-	100	100	100	100
eeg11.edf	1	4	100	75	80	80	89	77.78
eeg12.edf	4	1	100	0	100	100	100	66.67
eeg13.edf	7	6	100	100	71.4	71.43	85	84.62
eeg14.edf	8	30	93.33	90	96.8	96.77	95	93.44
eeg15.edf	8	21	95.24	90.5	90.9	95.45	93	93.02
eeg16.edf	19	43	93.02	90.7	97.7	97.73	95	94.25
eeg17.edf	10	3	100	100	25	25	57	57.14
eeg18.edf	9	0	-	-	100	100	100	100
eeg19.edf	1	12	91.67	83.3	84.6	92.31	88	88
eeg20.edf	2	22	94.46	90.9	91.3	91.3	93	91.11
Media	-	-	94.649	86	90.8	91.8	93	90.55

Tabla 4.5 – Resultados de clasificación de conjunto de datos Hospital de Helsinki sin filtrar.

Archivo EDF	Señal	Ataques	Sen α	Sen β	Esp α	Esp β	Pre α	Pre β
eeg1.edf	7	44	59.09	72.73	97.8	95.56	78.65	84.27
eeg2.edf	10	2	50	50	100	100	80	80
eeg3.edf	4	0	-	-	100	0	100	0
eeg4.edf	15	9	77.78	77.78	80	90	78.95	84.21
eeg5.edf	13	5	80	60	100	100	90.91	81.82
eeg6.edf	4	4	75	75	80	80	77.78	77.78
eeg7.edf	1	20	75	80	85.71	80.95	80.49	80.49
eeg8.edf	2	3	66.67	66.67	50	50	57.14	57.14
eeg9.edf	16	7	71.43	71.43	100	100	86.67	86.67
eeg10.edf	1	0	-	-	0	0	0	0
eeg11.edf	1	4	75	50	0	40	33.33	44.44
eeg12.edf	4	1	100	100	100	100	100	100
eeg13.edf	7	6	83.33	66.67	42.86	71.43	61.54	69.23
eeg14.edf	8	30	80	86.67	90.32	96.77	85.25	91.8
eeg15.edf	8	21	80.95	76.19	90.91	95.45	86.05	86.05
eeg16.edf	19	43	58.14	69.77	100	97.73	79.31	83.91
eeg17.edf	10	3	66.67	66.67	25	25	42.86	42.86
eeg18.edf	9	0	-	-	100	100	100	100
eeg19.edf	1	12	75	66.67	61.54	76.92	68	72
eeg20.edf	2	22	77.27	72.73	82.61	86.96	80	80
Media	-	-	73.61	71.11	74.34	74.34	73.35	70.13

En la Figura (4.14) se comparan gráficamente los resultados de precisión alcanzada por el algoritmo sobre el conjunto de datos de prueba del Hospital de Helsinki con el modelo SVM prefiltrado y sin filtrar sobre los ritmos alpha y beta.

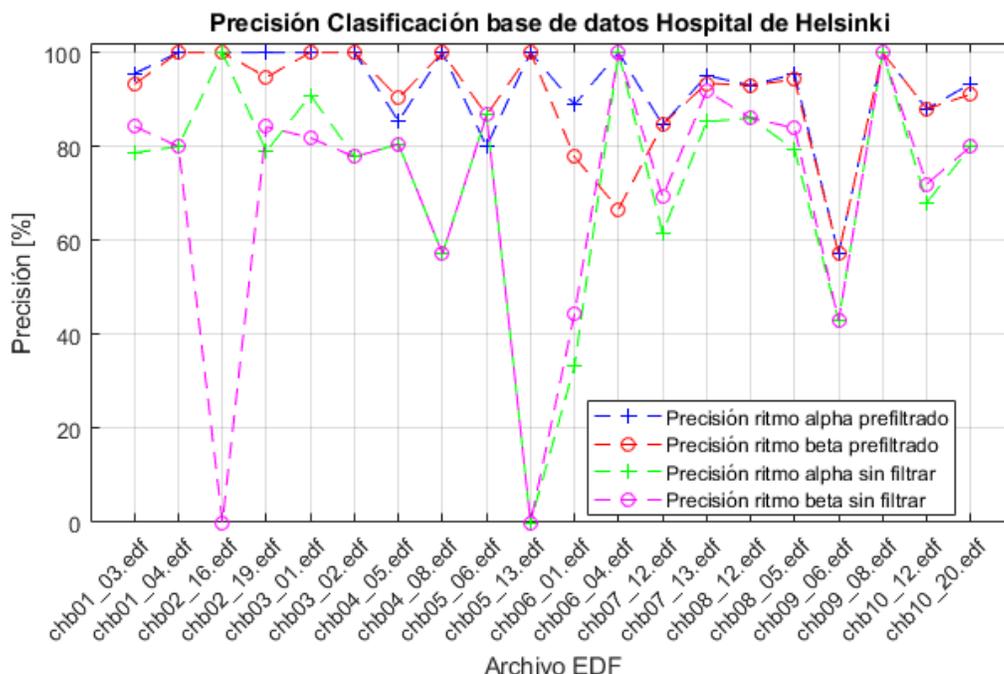


Figura 4.14 – Gráfica de precisión del clasificador para conjunto Hospital de Helsinki

Los resultados descritos fueron obtenidos luego de varios experimentos con distintos conjuntos de datos. En general, es posible conseguir mejores modelos de detección si se eligen con propiedad los datos de los conjuntos de entrenamiento y de manera balanceada, es decir, un mismo número de datos de entrenamiento para cada clase. La clasificación en los ritmos cerebrales alpha y beta corroboró la relación entre el incremento en la amplitud de estas ondas y la aparición de ataques epilépticos. La variabilidad de las características frente a un ataque epiléptico y en ausencia de uno fueron de gran utilidad para establecer etiquetas correspondientes a los respectivos intervalos. Del mismo modo, se determinó que existen canales en los cuales los ataques epilépticos presentan mayor energía en sus respectivas bandas de frecuencia y son más fáciles de detectar.

4.7. Conclusión del capítulo

En este capítulo se presentó la metodología conducente a la implementación de un algoritmo de detección automática de ataques de epilepsia en señales EEG. Los resultados evidenciaron la importancia de cada uno de los procesos individuales del algoritmo así como su desempeño en general. Se demostró la utilidad del preprocesamiento Savitzky-Golay al comparar los resultados de entrenamiento y clasificación de un mismo conjunto de datos filtrados y sin filtrar, resaltando la necesidad de eliminar el ruido presente en las señales. Disminuir la cantidad de datos a procesar a través de la descomposición de señales, usando Transformada Wavelet Discreta, demostró ser eficiente al reducir los tiempos de procesamiento sin generar pérdidas significativas de información. Por otro lado, la representación de los ritmos cerebrales espontáneos como coeficientes wavelet constituyó una valiosa herramienta para estudios basados en señales EEG, dada la posibilidad de identificar en las señales eventos en tiempo y frecuencia de manera simultánea. La caracterización de los ritmos permitió reducir aún más el volumen de datos a analizar, concentrando los valores de varias muestras en datos unidad equivalentes a un segundo de duración. La utilización de Máquina de Vectores de Soporte facultó la generación de distintos modelos clasificadores de datos, posibilitando la optimización de estos al variar sus parámetros. Otra de las grandes ventajas de este método resultó ser la capacidad de generar modelos clasificadores en base a múltiples características. Los ritmos cerebrales espontáneos alpha y beta probaron ser apropiados para detectar crisis epilépticas, presentando resultados similares en los experimentos. Se verificó el desempeño del algoritmo en función de los porcentajes de precisión alcanzados por el clasificador; entre 89.7% y 93%, considerando modelos de clasificación distintos para cada base de datos. Se concluye que la metodología propuesta y el algoritmo implementado son útiles para realizar la detección eficiente de ataques de epilepsia en señales EEG, así como la clasificación de cualquier otro tipo de señal biomédica.

CAPÍTULO 5

Conclusiones de la investigación

El análisis de señales EEG por medio de algoritmos matemáticos y estadísticos sin duda ofrece información fiable para la detección de enfermedades y trastornos originados en el sistema nervioso o el cerebro, tales como la epilepsia. Los avances alcanzados en la actualidad por diversos métodos enfocados en la detección automática de ataques epilépticos superan el 90 % de precisión en la mayoría de los casos, estableciendo un importante precedente en la resolución de complejas tareas de reconocimiento y clasificación de señales. La capacidad de los sistemas construidos sobre aprendizaje de máquinas para mejorar la calidad de vida de las personas es cada vez es mayor. En la actualidad los desafíos se enfocan en la simplificación de los cálculos y la reducción de la energía empleada para tales fines, dando lugar a sofisticados métodos de detección, no solo de trastornos como la epilepsia, sino también de otros padecimientos en señales biomédicas.

En esta investigación se desarrolló un algoritmo útil para realizar la detección de ataques de epilepsia en señales EEG, cumpliéndose el objetivo principal del trabajo. El algoritmo cuenta con distintas funcionalidades, entre las cuales destacan, la observación simultánea de múltiples señales EEG contenidas en un archivo EDF, el análisis comparativo de señales prefiltradas y la visualización de los efectos del ajuste de parámetros del filtro. Otras de sus propiedades son la representación gráfica en tiempo-frecuencia de los ritmos cerebrales espontáneos, el control de la extensión de las ventanas de extracción de características y la creación de diversos modelos de clasificación con parámetros ajustables. En cuanto a los objetivos específicos, se

expusieron ampliamente los antecedentes base de la investigación junto con el marco teórico de la metodología empleada, así como se logró implementar el algoritmo propuesto en MATLAB, logrando niveles de precisión satisfactorios en la detección de crisis epilépticas.

Enfocados en el desarrollo de investigaciones futuras de la misma índole, se propone la utilización de otras técnicas de descomposición de señales, como Transformada de Hilbert Huang o Descomposición Empírica en Modos. Se recomienda el empleo de selectores de características y balanceo de datos, o de diversos algoritmos clasificadores como Árboles de Decisión, K-Vecinos más Cercanos o Redes Neuronales. Además, se propone la determinación de los canales que mejor desempeño presenten en la detección de ataques epilépticos, con tal de reducir la cantidad de señales analizadas. También se plantea la importancia de implementar algoritmos similares enfocados en la detección de otros trastornos o enfermedades, así como también de emociones, actividad cerebral, entre otras muchas aplicaciones. Del mismo modo, se sugiere el empleo de métodos de este tipo para caracterizar y clasificar señales de otra naturaleza distinta a la de las señales biomédicas. Dadas las posibilidades de investigación que se desprenden de este trabajo, se resaltan sus múltiples contribuciones a la detección de eventos en señales EEG y al análisis de señales en general.

BIBLIOGRAFÍA

- [1] FISHER, R., ACEVEDO, C., ARZIMANOGLU, A., BOGACZ, A., CROSS, J., ELGER, C., ENGEL, J., FORSGREN, L., FRENCH, J., GLYNN, M., HESDORFFER, D., LEE, B., MATHERN, G., MOSHÉ, S., PERUCCA, E., SCHEFFER, I., TOMSON, T., WATANABE, M., WIEBE, S. (2014). *ILAE official report: A practical clinical definition of epilepsy*, 55(4). doi= 10.1111/epi.12550.
- [2] *Epilepsy*. (s.f.). World Health Organization. (<https://www.who.int/health-topics/epilepsy>).
- [3] ZHOU, M., TIAN, C., CAO, R., WANG, B., NIU, Y., HU, T., GUO, H., XIANG, J. (2018). Epileptic Seizure Detection Based on EEG Signals and CNN. *Frontiers in Neuroinformatics*, 12, 95. Taiyuan University of Technology. Taiyuan, China. doi=10.3389/fninf.2018.00095.
- [4] SELVATHI, D., MEERA, V. K. (2017). Realization of epileptic seizure detection in EEG signal usign wavelet transform and SVM classifier. *International Conference on Signal Processing and Comunication (ICSPC)* (pp. 18-22). Surfers Paradise, Australia. doi=10.1109/CSPC.2017.8305848.
- [5] ANAND, S., JAISWAL, S., GHOSH, P. K. (2017). Automatic Focal Epileptic Seizure Detection in EEG Signals. *IEEE International WIE Conference on Electrical and Computer Engineering (WIECON-ECE)* (pp. 103-107). Dehradun, India. doi=10.1109/WIECON-ECE.2017.8468906.

- [6] PANDA, R., KHOBRAGADE, P. S., JAMBHULE, P. D., JENGTHE, S. N., PAL, P. R., GANDHI, T. K. (2010). Classification of EEG signal using wavelet transform and support vector machine for epileptic seizure detection. *International Conference on Systems in Medicine and Biology* (pp. 405-408). Kharagpur, India. doi=10.1109/ICSMB.2010.5735413.
- [7] BERMÚDEZ CICCHINO, A. (2013). *Técnicas de procesamiento de EEG para detección de eventos*. Tesis de magister no publicada. Universidad Nacional de la Plata, Buenos Aires, Argentina.
- [8] LUNA DE LUÍS, M. (2021). *Procesamiento digital de señales de EEG para clasificación de trastornos psicóticos mediante aprendizaje de máquinas*. Memoria de grado no publicada. Universidad de Chile, Santiago, Chile.
- [9] DE LA FUENTE GUTIÉRREZ, C. (2020). *Eliminación de artefactos cardíacos en señales de electroencefalograma mediante filtro adaptativo*. Tesis de grado no publicada. Universidad Politécnica de Madrid, Madrid, España.
- [10] CHISAGUANO TOAPANTA, E. (2019). *Estudio del costo beneficio de técnicas de medición y control de señales biológicas que permitan autonomía en el movimiento de una prótesis para una extremidad superior*. Tesis de grado no publicada. Universidad Técnica de Cotopaxi, Latacunga, Ecuador.
- [11] BLANCO GÓMEZ, S. (2017). *Desarrollo de un sistema para análisis de señales electroencefalográficas*. Tesis de grado no publicada. Universidad Politécnica de Madrid, Madrid, España.
- [12] MOSQUERA GUERRERO, E. (2019). *Análisis e identificación de potenciales evocados en el electroencefalograma*. Tesis de grado no publicada. Universidad de Sevilla, Sevilla, España.
- [13] ALAGIA GIMENO, R. (2018). *Procesamiento de artefactos EEG para aplicaciones de comunicación y control*. Tesis de grado no publicada. Universidad Politécnica de Valencia, Valencia, España.

- [14] BACHILLER MATARRANZ, A. (2012). *Análisis de la señal de electroencefalograma mediante distancias espectrales para la ayuda en el diagnóstico de la enfermedad de Alzheimer*. Tesis de máster no publicada. Universidad de Valladolid, Valladolid, España.
- [15] CORTÉS, A., PORTILLA, L. (2014) *Prototipo para la adquisición y visualización de señales EEG para la onda P300*. Tesis de grado no publicada. Universidad de San Buenaventura, Bogotá, Colombia.
- [16] ARRIOLA, J. (2016). *Representación matemática de ondas cerebrales*. Tesis de magíster no publicada. Universidad Nacional del Sur, Bahía Blanca, Argentina.
- [17] BULLIDO ALONSO, V. (2016). *Adquisición y calibración automática de registros de electrofisiología neuronal*. Tesis de grado no publicada. Universidad Autónoma de Madrid, Madrid, España.
- [18] SÁNCHEZ CORZO, A. (2012). *Sonorización de señales EEG basada en estructuras musicales*. Tesis de grado no publicada. Universidad de los Andes, Bogotá, Colombia.
- [19] GÓMEZ, J., ORDÓÑEZ, O. (2018). *Estudio comparativo de técnicas de caracterización y clasificación automática de emociones a partir de señales del cerebro*. Tesis de grado no publicada. Universidad de Nariño, San Juan de Pasto, Colombia.
- [20] STEVENSON, N., TAPANI, K., LAURONEN, L. (2019). A dataset of neonatal EEG recordings with seizure annotations. *Sci Data*, 6(190039). doi=10.1038/sdata.2019.39.
- [21] GOLBERGER, A., AMARAL, L., GLASS, L., HAUSDORFF, J., IVANOV, P. C., MARK, R., STANLEY, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Physionet*, 101(23), e215-e220. doi=10.13026/C2K01R.

-
- [22] KUMAR, T.S., KANHANGAD, V., PACHORI, R.B. (2014). Classification of Seizure and Seizure-free EEG Signals using Multi-Level Local Patterns *19th International Conference on Digital Signal Processing*, (pp. 646-650). Hong Kong, China. doi=10.1109/ICDSP.2014.6900745.
- [23] CHOWDHURY, T.T., HOSSAIN, A., FATTAH, S.A., SHAHNAZ, C. (2019). Seizure and Non-Seizure EEG Signals Detection Using 1-D Convolutional Neural Network Architecture of Deep Learning Algorithm *1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT)*, (pp. 1-4). Dhaka, Bangladesh. doi=10.1109/ICASERT.2019.8934564.
- [24] ALDANA, Y.R., HUNYADI, B., REYES, E.J.M., RODRÍGUEZ, V.R., VAN HUFEL, S. (2019). Nonconvulsive Epileptic Seizure Detection in Scalp EEG Using Multiway Data Analysis. *IEEE Journal of Biomedical and Health Informatics*, 23(2), (pp 660-671). doi=10.1109/JBHI.2018.2829877.
- [25] GUPTA, A., SINGH, P., KARLEKAR, M. (2018). A Novel Signal Modeling Approach for Classification of Seizure and Seizure-Free EEG Signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(5), (pp 925-935). doi=10.1109/TNSRE.2018.2818123.
- [26] HASSANPOUR, H., MESBAH, M., BOASHASH, B. (2003). Comparative performance of time-frequency based newborn EEG seizure detection using spike signatures. *IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP'03)*. (pp II-389). doi=10.1109/ICASSP.2003.1202379.
- [27] VIDYARATNE, L.S., IFTEKHARUDDIN, K.M. (2017). Real-Time Epileptic Seizure Detection Using EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(11) (pp 2146-2156). doi=10.1109/ICASSP.2003.1202379.
- [28] ZABIHI, M., KIRANYAZ, S., INCE, T., GABBOUJ, M. (2013). Patient-specific epileptic seizure detection in long-term EEG recording in paediatric patients with intractable seizures. *IET Intelligent Signal Processing Conference (ISP 2013)*, (pp 1-7). doi=10.1049/cp.2013.2060.
-

-
- [29] ZARJAM, P., MESBAH, M., BOASHASH, B. (2007). Comparing two time-scale and time-frequency based methods in newborns' EEG seizure detection. *IEEE International Conference on Signal Processing and Communications (ICSPC)* (pp. 1579-1582). Dubai, United Arab Emirates. doi=10.1109/ICSPC.2007.4728635.
- [30] ACHARYA, D., RANI, A., AGARWAL, S., SINGH, V. (2016). Application of adaptative Savitzky-Golay filter for EEG signal processing. *Perspectives in Science*, 8(1), 677-679. doi=10.1016/j.pisc.2016.06.056.
- [31] SCHAFER, R.W. (2011). What Is a Savitzky-Golay Filter?. *IEEE Signal Processing Magazine*, 28(4), 111-117. doi= 10.1109/MSP.2011.941097.
- [32] OCAK, H. (2009). Automatic Detection of Epileptic Seizures in EEG Using Discrete Wavelet Transform and Approximate Entropy. *Expert Systems with Applications*, 36(2), 2027-2036. doi=10.1016/j.eswa.2007.12.065.
- [33] CASTRO, L.R., CASTRO S.M. (1995). Wavelets y sus Aplicaciones *1er. Congreso Argentino de Ciencias de la Computación*, (pp. 195-204). Bahía Blanca, Argentina.
- [34] AMIN, H.U., MALIK, A.S., AHMAD, R.F., BADRUDDIN N., KAMEL, N., HUSSAIN, M., CHOOI, W.T. (2015). Feature extraction and classification for EEG signals using wavelet transform and machine learning techniques. *Australas Physical and Engineering Sciences in Medicine*, 38(1) (pp. 139-149). doi=10.1007/s13246-015-0333-x
- [35] CARMONA, E.J. (2016). *Tutorial sobre Máquinas de Vectores de Soporte (SVM)*. Recuperado el 7 de julio de 2022 de: https://www.cartagena99.com/recursos/alumnos/apuntes/Tema8._Maquinas_de_Vectores_Soporte.pdf
- [36] ALVAREZ, A. (2014). Sistema de Archivos EDF/EDF+ utilizando MATLAB. *Journal 2014, Instituto de Electrónica Aplicada (IEA)*, 14, (pp.93-96). Recuperado el 1 de julio de 2022 de:

http://www.revistasbolivianas.ciencia.bo/scielo.php?script=sci_arttextpid=S1234-12342014000100014lng=ptnrm=isotlng=es

- [37] PROAKIS, J., MANOLAKIS, D. (2007). Introducción. *Tratamiento digital de señales*, (4a ed.), (pp. 1-32). Madrid, España: Pearson Educación.
- [38] OPPENHEIM, A., SCHAFER, R. (2009). Señales y sistemas en tiempo discreto. *Tratamiento de señales en tiempo discreto*, (3a ed.), (pp. 9-10). Madrid, España: Pearson Educación.
- [39] TAN, Y., WANG, J. (2004). A support vector machine with a hybrid kernel and minimal Vapnik-Chervonenkis dimensión. *IEEE Transactions on Knowledge and Data Engineering*, 16(4) (pp. 385-395). doi=10.1109/TKDE.2004.1269664.
- [40] HERNÁNDEZ, C., RAMÍREZ, J., GÓMEZ, P., RANGEL J., PEREGRINA H., CREUZ, I. (2017). EEG motor imagery signals classification using maximum overlap wavelet transform and support vector machine. *IEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)* (pp. 1-5). Ixtapa, Mexico. doi= 10.1109/ROPEC.2017.8261667.

Siglas

AI	Inteligencia Artificial.	32
ANN	Red Neuronal Artificial.	22
ARMA	Promedio Móvil Autorregresivo.	20
BCI	Interfaz Cerebro-Computadora.	2
BTD	Descomposición en Términos en Bloque.	20
CMIM	Maximización de Información Mutua Condicional.	22
CNN	Red Neuronal Convolutacional.	18
CPD	Descomposición Poliádica Canónica.	20
CWT	Transformada Wavelet Continua.	29
DCT	Transformada Coseno Discreta.	20
DFT	Transformada Discreta de Fourier.	27
DL	Aprendizaje Profundo.	33
DSP	Procesamiento Digital de Señales.	2
DWT	Transformada Wavelet Discreta.	19

- EDF** Formato de Datos Europeo. 44
- EEG** Electroencefalograma. 1
- EMD** Descomposición Modal Empírica. 19
- ERP** Potenciales Relacionados con Eventos. 15
- EWT** Empirical Wavelet Transform. 19
- FBM** Movimiento Browniano Fraccional. 20
- FD** Dimensión Fractal. 21
- FGN** Ruido Gaussiano Fraccional. 20
- FIR** Respuesta Finita al Impulso. 25
- H** exponente de Hurst. 20
- HHT** Transformada de Hilbert-Huang. 19
- HWPT** Harmonic Wavelet Packet Transform. 21
- ILAE** Liga Internacional Contra la Epilepsia. 1
- IMF** Funciones de Modo Intrínseco. 19
- KKT** Karush-Kuhn-Tucker. 38
- KNN** K-Vecinos Cercanos. 20
- LDA** Análisis Discriminante Lineal. 20
- ML** Aprendizaje de Máquina. 32
- MLP** Patrones Locales Multinivel. 19

MSE Error Cuadrático Medio. 26

OMS Organización Mundial de la Salud. 1

PA Potencial de Acción. 9

PSD Densidad Espectral de Potencia. 16

QP Programación Cuadrática. 38

RL Aprendizaje por Refuerzo. 34

RVM Máquina de Vectores de Relevancia. 21

SG Savitzky-Golay. 25

SL Aprendizaje Supervisado. 33

SNA Sistema Nervioso Autónomo. 6

SNC Sistema Nervioso Central. 6

SNP Sistema Nervioso Periférico. 6

SNR Relación Señal-Ruido. 24

SNS Sistema Nervioso Somático. 6

SSA Análisis de Espectro Sigular. 21

STFT Transformada Rápida de Fourier. 27

SVM Máquina de Vectores de Soporte. 19

TF Tiempo-Frecuencia. 21

TFD Distribuciones Tiempo-Frecuencia. 22

WGN Ruido Gaussiano Blanco. 49