



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Maestría en Ciencias Mecatrónica

Detección anticipada de eventos epilépticos empleando características  
no lineales

**Tesis**

Que como parte de los requisitos para obtener el Grado de

**Maestra en Ciencias**

**Presenta:**

Ing. Andrea Viviana Pérez Sánchez

**Dirigida por:**

Dr. Juan Pablo Amézquita Sánchez

San Juan del Río, Qro, México, Agosto 2021



Universidad Autónoma de Querétaro  
Facultad de Ingeniería  
Maestría en Ciencias Mecatrónica

**Detección anticipada de eventos epilépticos empleando características no lineales**

Tesis

Que como parte de los requisitos para obtener el Grado de

**Maestra en Ciencias**

Presenta:

**Ing. Andrea Viviana Pérez Sánchez**

Dirigida por:

**Dr. Juan Pablo Amézquita Sánchez**

**Dr. Juan Pablo Amézquita Sánchez**

Presidente

**Dr. Martin Valtierra Rodríguez**

Secretario

**Dr. Roque Alfredo Osornio Ríos**

Vocal

**Dr. J. Jesús de Santiago Pérez**

Suplente

**Dr. Jesús Rooney Rivera Guillen**

Suplente

Centro Universitario, Querétaro, Qro  
Junio 2021  
México

# RESUMEN

La epilepsia es un trastorno cerebral que afecta aproximadamente a 50 millones de personas en todo el mundo y se caracteriza por generar convulsiones recurrentes, que pueden poner a los pacientes en permanente riesgo por las caídas, ahogamientos, quemaduras y convulsiones prolongadas que pueden sufrir. Por estas razones, es de vital importancia proponer un método/metodología con la capacidad de predecir una crisis epiléptica minutos antes de su inicio, permitiéndole a los pacientes tomar su medicamento o ponerse a salvo en un lugar seguro con el fin de evitar alguna lesión.

En este sentido, este trabajo se desarrolló en 2 vertientes. 1) El desarrollo de una metodología basada en la transformada Wavelet de paquetes e indicadores no lineales como fractales e indicadores estadísticos y un clasificador basado en un árbol de decisiones para la predicción de crisis epilépticas. Por tal motivo, se analizan veintidós indicadores no lineales: cinco dimensiones fractales y diecisiete indicadores estadísticos, para medir los cambios en las propiedades de las señales ECG (Electrocardiograma). Posteriormente, a través del método de Kruskal-Wallis, los indicadores más discriminativos son seleccionados para ser empleados en la predicción de una crisis epiléptica hasta 15 minutos antes de su inicio. Finalmente, un clasificador basado en árbol de decisiones es empleado con el objeto de automatizar la predicción de las crisis epilépticas. Esta metodología, se validó empleando señales ECG monitoreadas en 7 señales con 10 ataques epilépticos, las cuales son proporcionadas por el Instituto de Tecnología de Massachusetts-Beth Israel Hospital (MIT-BIH). 2) Se desarrolló un sistema de adquisición de señales provenientes del cuerpo humano (oxigenación en sangre, ritmo cardíaco, respuesta galvánica de la piel y temperatura) con el fin de adquirir señales fisiológicas, las cuales han mostrado de acuerdo con la literatura su utilidad en la predicción de crisis epilépticas, debido a su relación con el sistema simpático.

En trabajos posteriores, la fusión de estas dos vertientes, permitirán un diagnóstico continuo y en línea, otorgando a los pacientes una herramienta que

mejorará su calidad de vida, ya que podrán evitar posibles lesiones a causa de una crisis.

**Palabras clave:** Detección anticipada de eventos epilépticos, señales ECG, transformada Wavelet, indicadores no lineales.

Dirección General de Bibliotecas UAQ

# ABSTRACT

Epilepsy is a brain disorder that affects about 50 million persons around the world. It is characterized by generating recurrent seizures, which can put patients in permanent risk because of falls, drowning, burns, and prolonged seizures that they can suffer. Hence, it is of vital importance to propose a methodology with the capability of predicting a seizure with several minutes before the onset, allowing that the patients take their precautions against injuries

In this regard, this work was developed in 2 aspects. 1) The development of a methodology based on the Wavelet package transform and nonlinear features like fractals and statistical features and a classifier based on a decision tree for the prediction of epileptic seizures. For this reason, twenty-two non-linear features are analyzed: five fractal dimensions and seventeen statistical features to measure the changes in the properties of the ECG (Electrocardiogram) signals. Then, through the Kruskal-Wallis method, the most discriminative indicators are selected to be used for predicting an epileptic seizure up to 15 minutes prior to its onset. Finally, a classifier based on the decision tree is used in order to automate the prediction of epileptic seizures. This methodology was validated using ECG signals monitored in 7 signals with 10 epileptic seizures, which are provided by the Massachusetts Institute of Technology-Beth Israel Hospital (MIT-BIH). 2) A system for acquiring signals from the human body (oxygenation in the blood, heart rate, galvanic response of the skin, and temperature) was developed in order to acquire physiological signals, which according to the literature have shown their usefulness in the prediction of epileptic seizures due to its relationship with the sympathetic system.

In future works, the fusion of these two aspects will allow a continuous and online diagnosis of patients, giving a tool that will improve their quality of life, since they can avoid possible injuries due to a crisis.

**Key words:** Seizure prediction, ECG signals, Wavelet transform, Nonlinear features.

## DEDICATORIA

*A mi familia, de quienes  
he recibido su apoyo  
incondicional y he con  
contado con ellos toda  
la vida*

Dirección General de Bibliotecas UAQ

# AGRADECIMIENTOS

Agradezco a Dios por haberme permitido iniciar y concluir esta etapa de mi vida.

Agradezco a mi familia, por apoyarme a lo largo de esta etapa académica.

A mi asesor Dr. Juan Pablo Amézquita Sánchez por todo su apoyo, paciencia, enseñanzas y consejos compartidos a lo largo de este trabajo.

A mis sinodales Dr. Martín Valtierra Rodríguez, Dr. Roque A. Osornio Ríos, Dr. J. Jesús De Santiago Pérez Jesús y Dr. Rooney Rivera Guillen por su apoyo en este trabajo.

Al Consejo Nacional de Ciencia y Tecnología CONACYT le agradezco la beca (No. 742275) recibida.

A mis amigos, compañeros, profesores y personal de la Universidad Autónoma de Querétaro Campus San Juan del Río por su apoyo a lo largo de esta etapa.

# ÍNDICE GENERAL

RESUMEN .....	I
ABSTRACT .....	III
DEDICATORIA.....	IV
AGRADECIMIENTOS .....	V
ÍNDICE GENERAL.....	VI
ÍNDICE DE FIGURAS .....	VIII
ÍNDICE DE TABLAS .....	XI
Capítulo 1.....	1
1.    Introducción.....	1
1.1.    Antecedentes.....	2
1.2.    Descripción del problema.....	6
1.3.    Justificación .....	8
1.4.    Hipótesis.....	9
1.5.    Objetivos.....	10
1.6.    Planteamiento general .....	11
Capítulo 2.....	13
2.    Fundamentación teórica.....	13
2.1.    Biopotenciales.....	13
2.2.    Procesamiento digital de señales.....	23
Capítulo 3.....	37
3.    Metodología.....	37
3.1.    Sistema de adquisición.....	39
3.2.    Materiales.....	46
3.2.1.    Recursos humanos .....	46
3.2.2.    Base de datos.....	47
3.2.3.    Preparación de las señales ECG de la base de datos .....	48



3.3.	Procedimiento para el análisis tiempo-frecuencia de las señales.....	50
<b>Capítulo 4.....</b>		<b>53</b>
4.	Resultados y discusión.....	53
4.1.	Sistema de adquisición.....	53
4.1.1	Puesta de experimento.....	53
4.1.2	Resultados.....	54
4.2.	Base de datos con señales ECG.....	58
4.3.	Discusión de resultados.....	64
<b>Capítulo 5.....</b>		<b>67</b>
5.	Conclusiones y prospectivas.....	67
5.1.	Conclusiones.....	67
5.2.	Prospectivas.....	68
<b>Referencias.....</b>		<b>70</b>
<b>Anexos.....</b>		<b>80</b>
Anexo 1.	Carta de consentimiento informado.....	80
Anexo 2.	Carta de confidencialidad.....	81
Anexo 3.	Artículo Presentado en el Coloquio 14 de Posgrado de Ingeniería 2020.....	82
Anexo 4.	Artículo Publicado en Mathematics 2020.....	84

# ÍNDICE DE FIGURAS

Figura 1.1. Planteamiento general (Autoría propia).....	11
Figura 2.1. Ilustración de la adquisición de EEG (Siuly <i>et al.</i> , 2017).....	14
Figura 2.2. Modelo de conexión electrodo-piel (Freeman, 2004).....	15
Figura 2.3. Posicionamiento de electrodos de acuerdo al sistema internacional de colocación de electrodos 10-20, (a) vista lateral y (b) vista superior (Jasper, 1958). .....	16
Figura 2.4. Colocación de electrodos de acuerdo al estándar de 12 derivaciones, (a) posición de electrodos de extremidades y (b) ubicación de electrodos precordiales (García, 2015).....	17
Figura 2.5. Ondas componentes de la señal electrocardiográfica (Vera <i>et al.</i> , 2006). .....	18
Figura 2.6. Pulsioxímetro: a) Sensor acoplado, b) partes del sensor (Parker, 2003). .....	20
Figura 2.7. Medición con divisores de voltaje: (a) método de corriente casi constante y (b) método de voltaje casi constante (Boucsein, 2012).....	21
Figura 2.8. Posicionamiento de electrodos palmarés (A – D), posición recomendada para el electrodo inactivo (E) utilizado en el registro endosomático y su relación con los dermatomas C6 – C8 (Venables & Christie, 1980).....	23
Figura 2.9. Pantalla principal del MATLAB (Autoría propia).....	24
Figura 2.10. Estructura de descomposición de DWT (Reda <i>et al.</i> , 2006). ....	26
Figura 2.11. Estructura de descomposición de la WPT (Reda <i>et al.</i> , 2006).....	27
Figura 2.12. Descripción general del árbol de decisiones (Shobha y Rangaswamy, 2018).....	35
Figura 3.1. Diagrama a bloques de la metodología de investigación propuesta (Autoría propia).....	37

Figura 3.2. Diagrama del sensor Max30105 (Maxim integrated, 2016).....	40
Figura 3.3. Diseño del capuchón del sensor de frecuencia cardiaca y oxigenación en sangre (a) diseño virtual, (b) diseño creado (Autoría propia). .....	40
Figura 3.4. Diagrama del sensor GSR v.1.2 (SeedStudio,2014).....	41
Figura 3.5. Esquema de Tarjeta de adquisición Arduino Mega 2560 (Arduino,2021). .....	42
Figura 3.6. Diagrama de conexiones de sistema (Autoría propia). .....	43
Figura 3.7. Sistema de monitoreo de los diferentes biopotenciales (ritmo cardiaco, oxigenación y actividad electrodérmica) (Autoría propia).....	43
Figura 3.8. Impresión de pantalla de código de lectura y apertura de archivo tipo .CSV (Autoría propia).....	44
Figura 3.9. Diagrama de flujo del sistema (Autoría propia). .....	45
Figura 3.10. Almacenamiento de los valores obtenidos en el archivo tipo .CSV (Autoría propia). .....	46
Figura 3.11. (a) Señal ECG un minuto antes y después de la crisis epiléptica y (b) señal ECG tomada como grupo sano (señal obtenida 1 hora antes de la aparición de una crisis epiléptica).....	50
Figura 3.12. Señal ECG sintética (Autoría propia). .....	51
Figura 3.13. Bandas de frecuencia obtenidas para el nivel 3 de descomposición para la señal sintética (Autoría propia).....	51
Figura 4.1. Sensores colocados en el paciente (Autoría propia).....	53
Figura 4.2. Puesta de experimento de sistema de adquisición de señales (Autoría propia).....	54
Figura 4.3. Gráfico comparativo de saturación de oxígeno en sangre entre el dispositivo desarrollado (gris) y el comercial (azul) de la señal 1 (Autoría propia).55	
Figura 4.4. Gráfico comparativo de ritmo cardiaco entre el dispositivo propio (naranja) y comercial (amarillo) de la señal 1 (Autoría propia).....	56

Figura 4.5. Gráfico comparativo de temperatura entre el dispositivo desarrollado (rojo) y comercial señal 1 (rosa) (Autoría propia).....	56
Figura 4.6. Gráfico de valores de GSR de la señal 1 (Autoría propia). ....	57
Figura 4.7. Descomposiciones estimadas para la WPT (primeras bandas de frecuencia) para la señal ECG de (a) grupo sano y (b) un minuto antes de la crisis (Autoría propia).....	60
Figura 4.8. Descomposiciones estimadas para la WPT (últimas bandas de frecuencia) para la señal ECG de (a) grupo sano y (b) un minuto antes de la crisis (Autoría propia). ....	60
Figura 4.9. Distribución de los valores de indicadores (eje y) para FC (BF-9), FC (BF-13) y FI (BF-12), para pacientes con ritmo cardíaco normal (GS) y pacientes con crisis epilépticas, en intervalos de 1 minuto hasta 15 minutos (eje x), antes de su ocurrencia (Autoría propia).....	62

# ÍNDICE DE TABLAS

Tabla 3.1. Características de los sensores Max30105 y GSR v.1.2. ....	41
Tabla 3.2. Registro en tiempo de las crisis epilépticas presentadas durante el estudio de ECG. ....	48
Tabla 3.3. Valores de indicadores no lineales, para cada una de las bandas de frecuencia (FB) de la señal sintética. ....	52
Tabla 4.1. Valores de error obtenidos para cada medida adquirida. ....	58
Tabla 4.2. Valores de P obtenidos de los indicadores más discriminantes. ....	63
Tabla 4.3. Comparación cualitativa del presente trabajo y trabajos recientes en el área de predicción de crisis epilépticas. ....	64

# Capítulo 1

## 1. Introducción

La epilepsia es una afección neurológica que aqueja aproximadamente a 50 millones de personas a nivel mundial, la cual se caracteriza por producir convulsiones en el ser humano que comienzan en el cerebro (OMS, 2019). En particular, el cerebro tiene miles de millones de células nerviosas que controlan la forma en que el ser humano piensa, siente y se mueve, los cuales son representados por medio de señales o impulsos eléctricos con el fin de enviar mensajes de una célula nerviosa a otra. Si los mensajes se interrumpen, o las señales eléctricas no se apagan cuando ya no son necesarias, esto puede causar un breve cambio en la forma en que funciona el cerebro, que a su vez esta interrupción o acumulación de señales eléctricas puede desembocar en una convulsión (Epilepsy Society, 2016).

Generalmente, las personas con epilepsia pueden llegar a tener problemas físicos, por ejemplo, fracturas y hematomas por lesiones relacionadas con convulsiones, así como afecciones psicológicas tales como ansiedad y depresión (OMS, 2019). Estos factores pueden llegar a afectar de manera negativamente su calidad de vida de los pacientes, así como a los miembros de la familia que cuida de ellos, esto debido a que las crisis epilépticas son impredecibles, lo cual representa una causa potencial de lesiones, muerte y alta estigma en la sociedad; además, de representar un gran costo económico en términos de atención médica (Taylor *et al.*, 2011; Vaurio *et al.*, 2016). Los efectos negativos en la calidad de vida pueden verse vinculados a relaciones familiares, sociales, oportunidades de empleo, educación y capacidad de funcionar de manera independiente (England *et al.*, 2012). Además, el riesgo de muerte prematura en personas con epilepsia es tres veces mayor que la población general. Una gran cantidad de muertes relacionadas con la epilepsia son potencialmente prevenibles, ya que estas muertes

son causadas por caídas, ahogamientos, quemaduras y convulsiones prolongadas (OMS,2019). Por estas razones, es necesario desarrollar métodos o metodologías que sean capaces de alertar anticipadamente al paciente de una posible crisis epiléptica. La capacidad de anticipar una convulsión o crisis epiléptica antes de su inicio permitiría a los pacientes, familiares y personal encargado de sus cuidados tomar precauciones contra las lesiones y abrir la puerta a un nuevo tratamiento oportuno para prevenir o controlar las convulsiones.

### 1.1. Antecedentes

En los últimos años, diversas investigaciones enfocadas a la predicción de crisis epilépticas han sido presentadas a nivel internacional (Asharinda *et al.*, 2020; Giannakakis *et al.*, 2019; Jana *et al.*, 2019; Tsiouris *et al.*, 2018; Billeci *et al.*, 2018; Jukić *et al.*, 2018; Choudhury *et al.*, 2018; Popov *et al.*, 2017; Pavei *et al.*, 2017). Estas investigaciones se han enfocado en el análisis de diversos biopotenciales tales como electroencefalogramas (EEG), electrocardiogramas (ECG), electro-dérmicas, respiración, entre otras con el fin de estimar características en estas señales que permitan ser asociadas a la predicción de crisis epilépticas. Por ejemplo, Ramgopal *et al.* (2014) establecieron una relación entre las crisis epilépticas y la secreción de sudor, mostrando que existen cambios en la actividad simpática del cerebro durante una crisis epiléptica. Este hallazgo implica que este tipo bioseñal se puede utilizar para detectar una crisis. Popov *et al.* (2017) combinaron indicadores tales como media, mediana, desviación estándar, histogramas, coeficientes de una aproximación polinomial de 1° grado con una máquina de soporte vectorial para predecir 20 minutos antes una crisis epiléptica analizando la variabilidad del ritmo cardíaco, (HRV por sus siglas en inglés *Heart Rate Variability*). Los autores emplearon un total de 18 señales de ECG para poder validar su estudio, dando como resultado una eficacia del 78.52 %. Es importante mencionar que este trabajo fue inspirado por los resultados obtenidos por Kolsal *et al.* (2014) & Nei *et al.* (2016), donde menciona que las convulsiones afectan directamente la frecuencia cardíaca, lo cual genera aumentos transitorios en la

frecuencia cardiaca y la presión arterial. Tsiouris *et al.* (2018) combinaron la transformada wavelet, momentos estadísticos, correlación cruzada y redes neuronales convolucionales para predecir una crisis epiléptica 15 minutos antes de su aparición, obteniendo como resultado una eficacia del 99.28%. Los autores emplearon un total de 24 señales de EEG para poder validar su estudio. Giannakakis *et al.* (2019) emplearon parámetros de HRV en el dominio del tiempo (frecuencia cardíaca, desviación estándar de los intervalos RR del corazón, desviación estándar de la frecuencia cardíaca) y parámetros espectrales de HRV (energía en la banda de frecuencia baja (LF por sus siglas en inglés *Low Frequency*) (0.04-0.15 Hz) energía en la banda de frecuencia alta (HF por sus siglas en inglés *High Frequency*) (0.15-0.4 Hz), HF normalizada, LF normalizada, potencia total), para combinarlos con una máquina de aprendizaje, para identificar características en las señales ECG que permitan predecir una crisis epiléptica. Los autores reportan una eficacia del 77.1% para 21.8 segundos antes de la crisis; por lo que los autores concluyen que es necesario el seguir investigando otros métodos, técnicas, para poder incrementar la eficiencia en la predicción de crisis epilépticas. Por otro lado, Aileni *et al.* (2019) establecieron una relación entre varias señales eléctricas (EEG, ECG, actividad electrodérmica (EDA por sus siglas en inglés *Electrodermal Activity*), fotoplethismografía (PPG por sus siglas en inglés *Photoplethysmogram*)) provenientes del cuerpo humano. A pesar de los buenos resultados que se han reportado a nivel internacional, estos se han concentrado en predecir una crisis epiléptica pocos minutos antes del evento, además de requerir una gran cantidad de procesamiento, lo cual puede limitar una implementación en línea. Por lo tanto, es de vital importancia un método o metodología capaz de predecir una crisis con suficiente tiempo, además de requerir una cantidad de procesamiento baja, permitiendo un diagnóstico continuo y en línea.

Con respecto al ámbito nacional, los estudios se han centrado en evaluar los principales cambios en biopotenciales durante una crisis epiléptica. Por ejemplo, Sica (2012) encontró que existen dos tipos de anomalías en el ritmo cardiaco



durante una crisis epiléptica: (1) acortamiento del intervalo Q-T (tiempo que emplean los ventrículos desde que producen una contracción, hasta su recuperación y preparación para el próximo latido) y (2) el espacio de propagación del intervalo Q-T. De igual manera, De Aguirre (2012) investigó el rol del sistema nervioso autónomo en la regulación fisiológica cronotrópica e inotrópica de la función cardíaca en pacientes con epilepsia. El autor basado en sus resultados mencionó que las manifestaciones cardíacas ictales dependen de la interacción entre el estado autonómico interictal, la descarga autonómica ictal, el comportamiento de los reflejos cardio respiratorios y cardiovasculares durante la crisis. García-Zamora *et al.* (2012) señalaron que el funcionamiento cardíaco puede variar ostensiblemente durante una crisis de epilepsia genuina, fundamentalmente en los casos de crisis generalizadas; en esas circunstancias el ritmo cardíaco puede acelerarse o lentificar llegando, incluso, a la asistolia que puede prolongarse por varios segundos, en oportunidades también es posible observar arritmias o taquiarritmias de diferente magnitud; de allí su recomendación de monitorear no solo el electroencefalograma sino también el electrocardiograma al estudiar a estos pacientes (García-Zamora *et al.*, 2012). Oliveros-Oliveros *et al.* (2015) establecieron una representación matemática para encontrar un foco epiléptico sobre la corteza cerebral usando señales de EEG. Con esta formulación matemática los autores pueden establecer un método de colocación más eficiente para medir las señales de EEG de una persona con epilepsia. Por otro lado, Cavazos (2017) empleó una máquina de soporte vectorial para poder clasificar señales EEG que correspondan con una crisis epiléptica. El autor menciona que una eficiencia del 74.63% fue obtenida con el fin de poder distinguir señales EEG de personas con crisis epilépticas de otro tipo de procesos.

Los trabajos reportados a nivel nacional (Sica, 2012; De Aguirre, 2012; García-Zamora *et al.*, 2012; Cavazos, 2017) permiten observar que existe una aparente relación entre los biopotenciales tales como ritmo cardíaco, actividad eléctrica del cerebro con las crisis epilépticas, lo cual es de suma importancia ya que en este

trabajo de tesis se enfocará en tratar de identificar esos cambios a través de indicadores no lineales para poder predecir una crisis epiléptica. Es muy importante mencionar que a nivel nacional no se encontraron trabajos que se enfoquen en la predicción anticipada de crisis epilépticas.

Finalmente, en el ámbito local, específicamente dentro de la Universidad Autónoma de Querétaro (UAQ), existen diversos trabajos relacionados con el diagnóstico, predicción de enfermedades y estudios de la calidad de vida ante una enfermedad. Por ejemplo, Ramírez (2013) realizó un estudio sobre la calidad de vida en los pacientes con epilepsia. En este estudio se encuestaron a 30 personas con epilepsia realizando distintas preguntas con el objetivo de conocer el nivel de calidad de vida con el que cuentan las personas encuestadas, observándose que las personas con epilepsia ven mermada su calidad de vida. En cuanto al uso de técnicas de procesamiento aplicadas para la detección anticipada de enfermedades existen diversos trabajos en la UAQ, por ejemplo, Vázquez (2013) desarrolló una metodología basada en el procesamiento de imágenes, las cuales fueron obtenidas mediante una cámara termográfica para realizar la detección temprana de pie diabético. Jiménez (2015) segmentó de forma automática imágenes termográficas para detectar ulceraciones en la planta de los pies de personas que presentaban pie diabético. Vega (2016) desarrolló un método basado en el procesamiento de imágenes obtenidas a través de una cámara termográfica con el fin de la detección de cáncer de mama. Recientemente, Cruz (2018) desarrolló una técnica basada en la descomposición empírica de modos, fractales y redes neuronales para la clasificación automática del pensamiento (derecha, izquierda y reposo) usando señales EEG. Pérez (2018) propuso la transformada wavelet para analizar señales ECG con el fin de predecir una crisis epiléptica. La autora reporta una eficiencia del 95% para poder predecir el evento epiléptico hasta 5 minutos antes. Chaves (2018) realizó una investigación para sintetizar 3 moléculas análogas al levetiracetam (anticonvulsivo comúnmente usado), esto para ofrecer una alternativa farmacológica a pacientes fármaco resistentes, obteniendo como resultado un

retardo en el desarrollo de crisis convulsivas. Por otro lado, Vargas (2019) propuso una metodología basada en la descomposición empírica de modos, medidas no lineales y redes neuronales para la detección anticipada de un infarto. Piña (2019) combinó la dimensión fractal y lógica difusa para detectar anticipadamente un infarto con una anticipación máxima 1 hora antes del evento. Carrasco (2019) diseñó y desarrolló un sistema de adquisición y procesamiento de señales cardíacas basado en el sistema LabVIEW y la transformada de Fourier. Ruiz (2019) combinó la transformada wavelet y los parámetros de Hjorth para realizar la clasificación de tres pensamientos imaginados (reposo, izquierda y derecha).

De acuerdo a los trabajos realizados dentro de la UAQ, se observa que estos de manera general se han centrado en el diagnóstico y predicción de enfermedades. Específicamente para la epilepsia se han desarrollado métodos para mitigar los efectos de las crisis epilépticas, estudios para saber qué consecuencias trae esta enfermedad en la vida cotidiana del paciente, así como un trabajo de tesis de nivel licenciatura que se enfocó en poder predecir anticipadamente crisis epilépticas.

A pesar que actualmente existen métodos para la detección de crisis epilépticas, es importante seguir investigando este tema con el fin de poder desarrollar nuevas metodologías con el fin de incrementar la eficiencia de predicción, reducir la cantidad de carga computacional, así como evaluar una mayor ventana de tiempo de predicción. Como resultado, este tipo de metodologías pueden ser implementadas en sistemas que proporcionen un diagnóstico continuo y en línea, para permitir al paciente con epilepsia mejorar su calidad de vida, ya que tendrían tiempo suficiente para ponerse a salvo y evitar lesiones a causa de la crisis.

## **1.2. Descripción del problema**

Los biopotenciales son señales que se caracterizan por estar embebidas en una gran cantidad de ruido por diferentes fenómenos provenientes de ondas

electromagnéticas, movimientos musculares, red de alimentación y el contacto de los electrodos con la piel (Treo *et al.*, 2009). Adicionalmente, los biopotenciales son señales que presentan propiedades no estacionarias (señales que presentan cambios en sus características tales como amplitud, frecuencia, entre otros). Por lo tanto, este tipo de señales tienen que ser analizadas a través de técnicas de procesamiento de señales avanzadas que permitan detectar características en la señal que permitan indicar la existencia de alguna anomalía que pueda ser asociada al fenómeno estudiado. Por ejemplo, Acharya *et al.* (2018) describen varias técnicas de procesamiento de señales que han sido utilizadas para la predicción de una crisis epiléptica. Algunas de las técnicas que han sido utilizadas para este propósito son la descomposición empírica de modos, algoritmos espectrales, entropía, frecuencia angular, segundo, tercero y cuarto momento estadístico, parámetros de Hjorth, correlación, covarianza, etc. Además de describir los tipos de clasificadores utilizados los cuales son máquinas de soporte vectorial, máquinas de soporte vectorial de mínimos cuadrados, redes neuronales probabilísticas, redes neuronales convolucionales. A pesar de ser unas excelentes técnicas de procesamiento, estas pueden incrementar la carga computacional de un sistema de diagnóstico, limitando que el resultado sea de forma instantánea, por lo que otras técnicas de procesamiento capaces de trabajar con señales no estacionarias de baja amplitud y embebidas en ruido deben ser exploradas.

En años recientes, los índices conocidos como fractales e indicadores estadísticos, índices de carga computacional baja, han sido empleados para diagnosticar la condición de motores de inducción (Amezquita-Sanchez *et al.*, 2016; Saucedo-Dorantes *et al.*, 2019), estructuras civiles (Amezquita-Sanchez *et al.*, 2015; Babajanian *et al.*, 2019), neurociencia (Ahmadlou *et al.*, 2011; Ieracitano *et al.*, 2019), entre otras disciplinas. A lo largo de estos años, diversos algoritmos para el cálculo de la dimensión fractal tales como: Katz, Higuchi, Sevcik, Dimensión de caja y Petrosevick, así como diversos índices estadísticos como energía, media, Kurtosis, entre otros, han presentado buenos resultados en los trabajos antes

mencionados; por lo tanto, estos métodos o índices serán evaluados en este trabajo de tesis con el fin de identificar características en biopotenciales que permitan predecir una crisis epiléptica. La dimensión fractal se caracteriza por ser una medida que estima las similitudes geométricas tanto de señales estacionarias como no estacionarias (Amezquita-Sanchez *et al.*, 2017). Por otro lado, los índices estadísticos son capaces de medir cambios en las propiedades de las señales no estacionarias tales como dispersión asimetría, convergencia, entre otras características (Abdullah,2005). En este sentido, estas técnicas o métodos de procesamiento pueden llegar a ser consideradas herramientas adecuadas para estimar características en biopotenciales, ya que estas señales pueden cambiar de acuerdo con la condición del paciente, sano o con posibilidad de crisis epiléptica, generando un cambio en el valor del fractal o indicador estadístico.

Por lo tanto, mediante este trabajo de tesis se pretende obtener a base de técnicas de procesamiento de baja carga computacional, tales como dimensión fractal e índices estadísticos, una metodología no invasiva que estime características adecuadas en biopotenciales y se pueda realizar su implementación en línea, una detección temprana de crisis epilépticas y, con ello, lograr que la persona afectada realice las acciones que requiera para minimizar los efectos que pueda tener la crisis.

### **1.3. Justificación**

La epilepsia se caracteriza por producir convulsiones en los pacientes que presentan esta enfermedad (OMS, 2019), lo cual genera que la calidad de vida de estos se vea afectada, ya que proporciona una incertidumbre de cuándo podrían presentar una crisis que les pudiera llegar a producir una lesión y en ciertos casos la muerte (Ramírez, 2013). En este sentido, se genera una gran necesidad por desarrollar métodos o metodologías que ayuden a mejorar la calidad de vida de un paciente con epilepsia, ya que estas le ayudarían a mejorar su incertidumbre ante una crisis y las posibles lesiones.

Durante los últimos años, diversos métodos o metodologías basados en el análisis de biopotenciales han sido propuestas y revisadas en los antecedentes para la predicción de crisis epilépticas. Los biopotenciales han demostrado ser capaces de monitorear características tales como cambios en el ritmo cardíaco, actividad eléctrica del cerebro, entre otras características que pueden ser asociadas a una crisis epiléptica. Sin embargo, los trabajos reportados se han enfocado en la predicción de una crisis epiléptica pocos minutos antes del evento, así como el uso de técnicas de procesamiento de gran carga computacional, lo que podría generar una incertidumbre en un paciente/persona si será capaz de recibir a tiempo un tratamiento médico, ponerse en un lugar a salvo o en ciertos casos si llegará al hospital (England et al., 2012; Taylor et al., 2011).

Por lo tanto, la principal justificación de este trabajo de tesis es la generación de una metodología basada en procesamiento avanzado de baja carga computacional y baja cantidad de indicadores que permita el análisis correcto de biopotenciales con el fin de poder predecir de manera anticipada una crisis epiléptica, logrando mejorar la calidad de vida de un paciente con epilepsia, ya que tendrían tiempo suficiente para ponerse a salvo, llegar a un hospital o en ciertos casos tomar medicina para aminorar los efectos de la crisis.

#### **1.4. Hipótesis**

Mediante la utilización de transformada Wavelet de paquetes, indicadores no lineales tales como dimensión fractal, índices estadísticos y clasificadores basados en árboles de decisión, es posible generar una metodología que permita predecir una crisis epiléptica a través de señales fisiológicas, mejorando la carga computacional y el tiempo de predicción en comparación con los trabajos reportados actualmente en la literatura.

## **1.5. Objetivos**

### **1.5.1. Objetivo general**

Proponer y desarrollar una metodología nueva, eficiente y de baja carga computacional basada en el procesamiento de señales mediante la transformada Wavelet, la extracción de características mediante indicadores lineales y no lineales tales como los algoritmos de Katz, Higuchi, Sevcik, Petrosian, dimensión caja, kurtosis, energía y otros, y en el diagnóstico automático mediante un clasificador basado en árboles de decisión para el diagnóstico anticipado de crisis epilépticas.


### **1.5.2. Objetivos particulares**

1. Programar el algoritmo de la transformada wavelet haciendo uso del software MATLAB® para separar la señal en bandas de frecuencia relacionadas con las señales fisiológicas medidas.
2. Programar los algoritmos de Katz, Higuchi, Sevcik, Petrosevick, dimensión caja, kurtosis, energía, etc. haciendo uso del software MATLAB® para estimar las características de una señal en el dominio del tiempo.
3. Analizar las señales adquiridas por el Hospital de Boston localizado en los Estados Unidos de América mediante los algoritmos de procesamiento programados en el objetivo 1 y 2, con el fin de poder predecir una crisis epiléptica.
4. Realizar un análisis estadístico empleando el método de Kruskal-Wallis para poder estimar las características más discriminantes estimadas en el objetivo 3 para predecir una crisis epiléptica.
5. Diseñar un clasificador de inteligencia artificial; empleando las características más discriminantes estimadas en el objetivo 5 para poder predecir una crisis epiléptica de forma automática.

6. Realizar un análisis estadístico de las diferentes pruebas con el fin de validar la metodología propuesta buscando realizar el diagnóstico de manera eficiente.
7. Comparar los resultados obtenidos cualitativamente con otros algoritmos, para validar su eficiencia manteniendo una carga computacional capaz de ser implementada.
8. Desarrollar un sistema capaz de medir y adquirir señales fisiológicas tales como oxigenación, pulsaciones, resistencia galvánica a través de sensores de resistencia galvánica de la piel, pulsioxímetros, los cuales permitan analizar el comportamiento de las señales fisiológicas ante la posibilidad de un evento epiléptico.

## 1.6. Planteamiento general

La propuesta para el desarrollo de la metodología de diagnóstico anticipado de crisis epilépticas se muestra en el diagrama de la Figura 1.1 en el cual se pueden apreciar las diferentes etapas que deben seguirse.



**Figura 1.1.** Planteamiento general (Autoría propia).

- **Adquisición:** En esta etapa se obtiene la información de las señales fisiológicas de los pacientes con diagnóstico clínico de epilepsia.



- **Procesamiento:** Durante esta etapa se realizará el cálculo de diferentes indicadores no lineales, para esto se emplearán técnicas de procesamiento de señales en tiempo frecuencia.
- **Discriminación:** En este paso, se evaluarán el potencial de las características encontradas en la señal para discriminar entre una persona sana y una persona que pueda sufrir una crisis epiléptica.
- **Clasificación:** Una vez procesadas las señales se realiza la clasificación de las características obtenidas de las señales con el objetivo de determinar entre una persona sana y una persona que sufrirá de una crisis de forma automática.

# Capítulo 2

## 2. Fundamentación teórica

En este capítulo se presenta una breve revisión de las herramientas teóricas y los conceptos necesarios para el desarrollo de este trabajo de tesis.

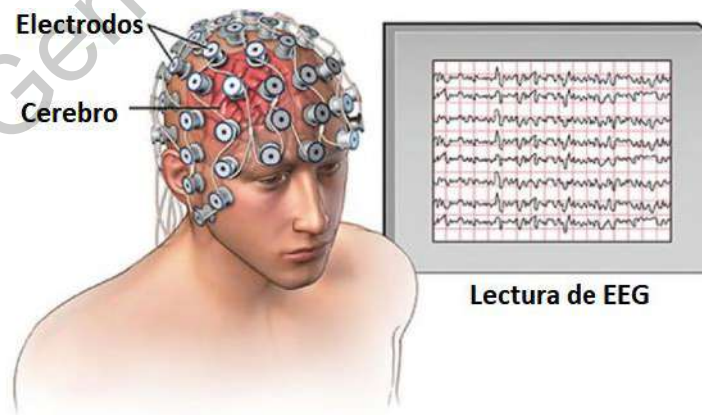
### 2.1. Biopotenciales

Actualmente, la mayor parte de la investigación relacionada con la predicción de ataques epilépticos en la literatura está enfocada al análisis de señales de EEG (Asharindavida *et al.*, 2020; Jana *et al.*, 2019; Tsiouris *et al.*, 2018; Kiral-Kornek *et al.*, 2018; Jukić *et al.*, 2018; Choudhury *et al.*, 2018), donde resultados buenos han sido reportados; sin embargo, el EEG no es cómodo, además de la susceptibilidad a artefactos que se dan debido a diferentes causas, como mala ubicación de los electrodos, cuero cabelludo no limpio, impedancia de los electros, artefactos fisiológicos (parpadeo, movimientos oculares, actividad muscular) y vibraciones del electrodo por el movimiento del paciente (Zhang *et al.*, 2009, GuruvaReddy & Narava, 2013), por tanto, la adquisición de este biopotencial limita una futura implementación. Esta es una de las razones por la que se comienza a investigar la relación de las crisis epilépticas con otros biopotenciales tales como las señales provenientes del corazón (ECG), electrodérmicas, entre otras para la predicción de crisis epilépticas (Giannakakis *et al.*, 2019; Aileni *et al.* 2019; Giannakakis *et al.*, 2019; Nei *et al.*, 2016; Popov *et al.*, 2017; Kolsal *et al.*, 2014; Ramgopal *et al.*, 2014; Sica, 2012; De Aguirre, 2012; García-Zamora *et al.*, 2012); la adquisición de estos biopotenciales provee las siguientes ventajas como la comodidad del paciente, la dificultad de colocación de los sensores es menor que para la adquisición de señales EEG (Zhang *et al.*, 2009). En este sentido, es importante continuar investigando los cambios que presentan en este tipo de señales, para poder realizar métodos que permitan una detección continua y en línea de características que permitan generar un método de predicción de crisis epilépticas.

### 2.1.1. Electroencefalograma

El electroencefalograma (EEG) se caracteriza por permitir la medición de los potenciales que refleja la actividad eléctrica del cerebro humano. Es por ello que, el estudio de la actividad eléctrica del cerebro, a través de EEG, es una de las herramientas más importantes para diagnosticar desórdenes neurológicos como epilepsia, tumores cerebrales, lesiones cerebrales, desórdenes del sueño, demencia (Adeli *et al.*, 2003).

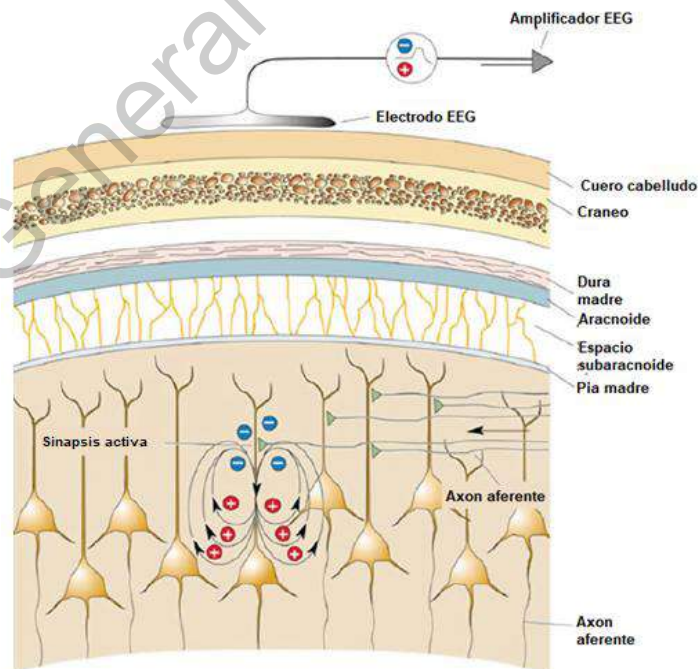
Durante un estudio de EEG, diversos electrodos son colocados en distintas posiciones en la superficie del cuero cabelludo empleando un pegamento temporal. En este sentido, cada electrodo está conectado a un amplificador y una máquina de grabación de EEG con el fin de que las señales eléctricas del cerebro sean convertidas en líneas onduladas en una pantalla de computadora para grabar los resultados (Siuly *et al.*, 2017). La Figura 2.1 presenta un ejemplo del acomodo o ubicación de los electrodos durante la toma del EEG. La cantidad de electrodos puede variar desde 1 a 256 electrodos, lo cual depende del estudio a realizar.



**Figura 2.1.** Ilustración de la adquisición de EEG (Siuly *et al.*, 2017).

Para poder medir las señales eléctricas del cerebro, es necesario contar con sensores que creen una interfaz entre la piel y los circuitos del electroencefalograma. Estos sensores son denominados electrodos y se colocan en el cuero cabelludo (ver Figura 2.2), los electrodos poseen un buen contacto mecánico y eléctrico, esto permiten establecer un contacto galvánico con el interior del cuerpo y son denominados electrodos resistivos o conductores (Siuly *et al.*, 2017).

Para que la diferencia de potencial entre los dos terminales de entrada del amplificador sea la misma que hay entre los dos puntos del cuerpo donde están aplicados los electrodos, es necesario que la corriente a través de estos sea tan pequeña que la caída de tensión en ellos sea inapreciable. La diferencia de potencial medida entre dos electrodos tiene entonces solo dos componentes: la señal bioeléctrica deseada y la diferencia de potenciales de semi-pila entre electrodos (tensión de offset) (Neuman, 2009).




**Figura 2.2.** Modelo de conexión electrodo-piel (Freeman, 2004).

Durante una medición de EEG es posible que se la señal presente más ruido o fluctuaciones no deseadas por diversas circunstancias, las cuales son descritas a continuación (Treo *et al.*, 2009):

- Movimiento del electrodo. Esto genera un cambio en la distribución de cargas en interfase Electrodo-Electrolito.
- Cambio en la distribución de cargas Electrodo-Electrolito. Esto produce un ruido alto (algunos mV), por esta este motivo se puede llegar a perder la señal de interés.

La amplitud de la señal EEG comúnmente está en un rango de 1 a 100  $\mu\text{V}$ , ya que la estructura del cerebro no es uniforme y la corteza está funcionalmente organizada, además esta amplitud también puede variar dependiendo del posicionamiento de los electrodos (Siuly *et al.*, 2017). El método estándar para la colocación de electrodos extracraneales es el sistema internacional de electrodos 10-20, donde el 10 y el 20 representan distancias reales entre electrodos vecinos; en este sentido, hay 10 o 20% del total de la parte frontal o posterior distancia derecha-izquierda del cráneo. Las posiciones están determinadas por 2 puntos: Nasion (1), que es el punto entre la frente y la nariz, nivelado con los ojos, e Inion (2) que es la prominencia ósea en la base del cráneo en la línea media en la parte posterior de la cabeza (Jasper, 1958). La Figura 2.3 presenta la posición del electrodo en el cerebro según el sistema internacional 10-20.

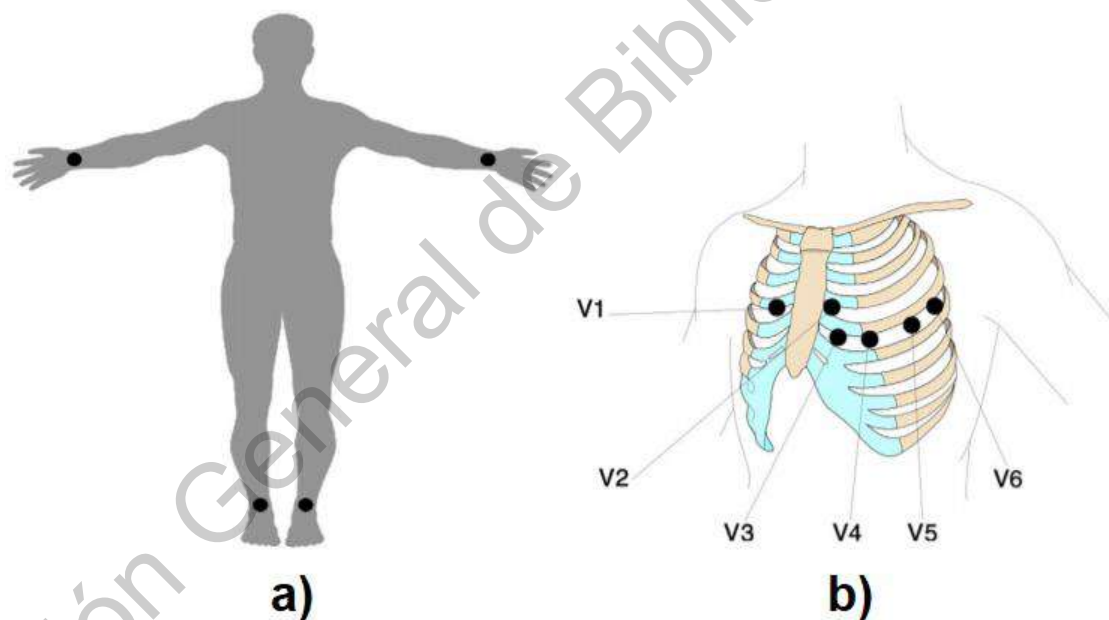


**Figura 2.3.** Posicionamiento de electrodos de acuerdo al sistema internacional de colocación de electrodos 10-20, (a) vista lateral y (b) vista superior (Jasper, 1958).

## 2.1.2. Electrocardiograma

El electrocardiograma (ECG) es empleado para medir la actividad eléctrica de las células del corazón, las cuales producen la contracción rítmica del corazón de acuerdo con un orden estricto y siempre de igual magnitud latido tras latido (Vera *et al.*, 2006). Gracias a esta medición, se han podido detectar anomalías cardíacas, arritmias, deterioro del miocardio, infartos, entre otros (Vera *et al.*, 2006).

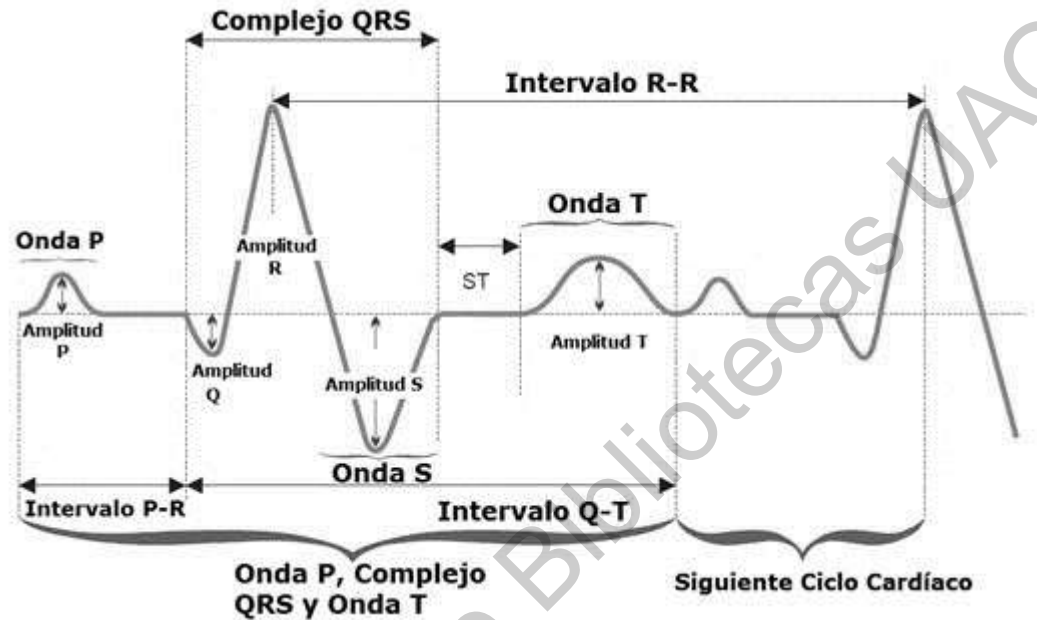
El estudio de ECG se basa en la colocación de 12 electrodos en el torso, los cuales son colocados sobre la piel limpia con un gel conductor para asegurar el correcto contacto piel-electrodo como se muestra en la Figura 2.4 (García, 2015).



**Figura 2.4.** Colocación de electrodos de acuerdo al estándar de 12 derivaciones, (a) posición de electrodos de extremidades y (b) ubicación de electrodos precordiales (García, 2015).

Las ondas de ECG son captadas por los electrodos durante la despolarización “activación” y repolarización “recuperación” miocárdica. Las distancias entre deflexiones u ondas se denominan segmentos o intervalos. Un periodo del ECG

perteneciente a un individuo sano consiste en una onda P, el complejo QRS, la onda T y la onda U, tal como se muestra en la Figura 2.5 (Vera *et al.*, 2006).



**Figura 2.5.** Ondas componentes de la señal electrocardiográfica (Vera *et al.*, 2006).

De acuerdo a la Figura 2.5, la señal electrográfica consta de los siguientes intervalos y segmentos, los cuales se describen con detalle a continuación:

- Onda P. Representa la despolarización auricular, tiene una duración de 110 ms y una amplitud 0.15 mV.
- Complejo QRS. Representa la despolarización de los ventrículos, presenta una duración de 120 ms y amplitud de 1.5 mV.
- Onda T. Representa la repolarización de los ventrículos y presenta una amplitud de 0.3 mV.
- Segmento ST. Representa el tiempo durante el que los ventrículos permanecen en estado activado y puede iniciarse la repolarización ventricular.

- Intervalo RR. Corresponde al intervalo de tiempo entre la onda R de un complejo QRS y la onda R del siguiente complejo QRS (duración de un latido).
- Intervalo QT. Corresponde al intervalo de tiempo entre el comienzo del complejo QRS y el final de la onda T, representando la duración de la sístole eléctrica, lo que representa el ritmo cardíaco, este intervalo tiene una duración de 400 ms.


La señal adquirida del ECG puede contener diversos elementos ajenos a la señal como son el ruido del sistema de adquisición, contracciones musculares, la interferencia de la red eléctrica (50 o 60 Hz), las variaciones de la línea base (0.15 a 0.3 Hz) y ruido electro quirúrgico producido por otros aparatos médicos (100 KHz a 1 MHz). Este ruido puede ser reducido con técnicas de preprocesamiento para que la señal obtenida sea lo más parecida a la señal real (Elhaj *et al.*, 2006; Cuesta, 1999; Friesen *et al.*, 1990).

### 2.1.3. Pulsioximetría

La pulsioximetría es una técnica utilizada para medir de forma no invasiva la saturación porcentual de oxígeno (SPO<sub>2</sub>) en la sangre, para esto combina los principios de la fotopleletismografía con las características de absorción óptica diferencial de los dos principales derivados de la hemoglobina: la oxihemoglobina (HbO<sub>2</sub>) y la desoxihemoglobina (RHb) (Allen, 2007). La fotopleletismografía se puede utilizar para la extracción de la frecuencia cardíaca, está monitorea los cambios en el volumen de sangre en el tejido (dedo, oreja) mediante el uso de emisiones de luz con dos longitudes de onda 660nm (roja) y 990 nm (infrarrojo) que son características de la oxihemoglobina y la desoxihemoglobina respectivamente esto se hace mediante un pulsioxímetro (ver Figura 2.6) (Hu *et al.*, 2013). La mayor parte de la luz se absorbe por el tejido conectivo, piel, hueso y sangre venosa en una cantidad constante, produciéndose un incremento de la absorción en la sangre arterial con cada latido y mediante la comparación de la luz que se absorbe en la



onda pulsátil con respecto a la absorción basal se calcula el  $SPO_2$  (Hu *et al*, 2013 & Allen, 2007).



**Figura 2.6.** Pulsioxímetro: a) Sensor acoplado, b) partes del sensor (Parker, 2003).


La señal PPG tiene características periódicas debido a la aparición de los latidos del corazón. Por lo tanto, también se puede utilizar para la extracción automática de la frecuencia cardíaca y también para la detección de convulsiones basada en la frecuencia cardíaca, además presenta menos molestias que el ECG, pero a menudo resulta en una extracción de la frecuencia cardíaca menos robusta que el ECG (Aileni *et al*, 2019). Debido a las características de baja frecuencia de la fotopletismografía, es menos sensible al ruido de alta frecuencia en comparación con el ECG. Sin embargo, la PPG es más sensible a artefactos de movimiento, pigmentación en la piel, alteración en coloración de uñas (para toma en dedos) (Rojas-Pérez, 2006).

#### 2.1.4. Actividad electrodérmica

La actividad electrodérmica se caracteriza por monitorear los fenómenos eléctricos pasivos y activos de la piel y sus apéndices (Johnson & Lubin, 1966). Estos fenómenos generan un cambio espontáneo y provocado por un sistema

complejo con elementos que muestran diferentes propiedades electro físicas (Johnson & Lubin, 1966). Existen 2 formas de monitorear los efectos dérmicos de la piel los cuales son endosomática y exosomática, siendo la medición exosomática la más empleada con el fin de observar cambios en la piel debido a una posible enfermedad (Boucsein, 2012). Esta medición se centra en medir la actividad electrodermal como una disminución de la resistencia o bien como el aumento de la conductancia de la piel (Boucsein, 2012).

Para poder obtener esta medición, se colocan 2 electrodos a la piel del paciente y se conectan en serie con una resistencia de referencia del sistema. Para realizar esta tarea existen 2 métodos: corriente casi directa y de voltaje casi constante como se muestra en la Figura 2.7, donde  $U_{tot}$  es el voltaje de fuente aplicado al sistema,  $U_1$  y  $U_2$  son voltajes parciales medidos en la variación de la  $R_1$  resistencia de la piel y  $R_2$  es una resistencia fija (Boucsein, 2012). Las fluctuaciones en el sistema electrodérmico se pueden leer a través de las variaciones de las tensiones parciales (Boucsein, 2012).

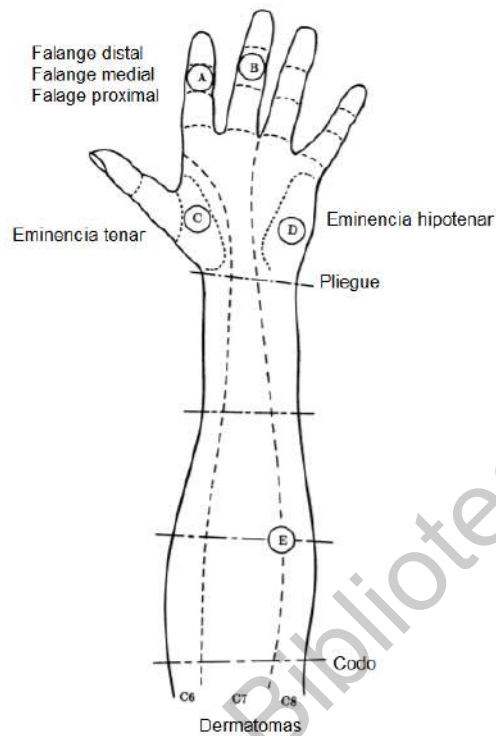


**Figura 2.7.** Medición con divisores de voltaje: (a) método de corriente casi constante y (b) método de voltaje casi constante (Boucsein, 2012).

Los electrodos se colocan en las palmas o la superficie interna de los dedos como sitios activos para el registro electrodérmico por las siguientes razones (Venables y Christie,1980):

- Los electrodos se pueden arreglar fácilmente, y esos sitios no son susceptibles de ser alterados por el movimiento.
- El tamaño del área disponible es suficiente.
- Estos sitios están relativamente libres de cicatrices.
- Los sitios de la palma muestran una actividad electrodérmica distinguida.

La Figura 2.8 muestra las áreas de adquisición palmar preferidas para la toma exosomática, de estas regiones la de las falanges mediales de los dedos índice y medio son la mejores para adquisiciones bipolares (sitios A y B). Estas falanges mediales son menos propensas a cicatrices y a efectos de movimiento que las proximales, y las falanges distales y las falanges de otros dedos proporcionan áreas más pequeñas para la fijación de electrodos (Edelberg,1967; Venables & Christie,1980).



**Figura 2.8.** Posicionamiento de electrodos palmarés (A – D), posición recomendada para el electrodo inactivo (E) utilizado en el registro endosomático y su relación con los dermatomas C6 – C8 (Venables & Christie, 1980).

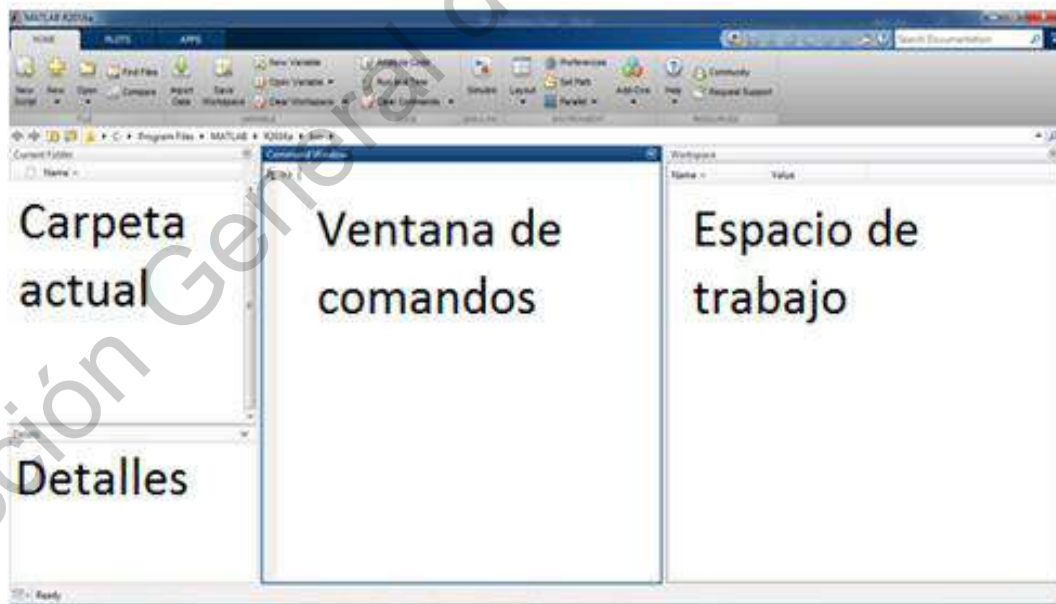
## 2.2. Procesamiento digital de señales

El procesamiento digital de señales es un área de la ingeniería electrónica que se concentra en la representación, transformación y manipulación de la información tales como señales en tiempo e imágenes. Por lo tanto, el procesamiento de señales en tiempo discreto se refiere al procesamiento de señales discretas en el tiempo o en el espacio. Esto implica que solo se conoce el valor de la señal en instantes o en puntos específicos, la cual es una condición necesaria para que la señal pueda ser procesada en un computador digital (Vignolo, 2008).

### 2.2.1. MATLAB

MATLAB (MATrix LABoratory) es un software comercial de alto nivel, el cual permite la manipulación de vectores o matrices (señales digitales), con el fin de visualizarlos, modelarlos, analizarlos y procesarlos. MATLAB provee un sencillo ambiente en el cual se diseñan las pruebas y algoritmos (Leis, 2011).

MATLAB se basa en una ventana principal, la cual a su vez está subdividida en 4 ventanas: (1) la ventana de comandos: ventana usada para el análisis de las señales), (2) la ventana espacio de trabajo: ventana empleada para visualizar las variables empleadas, así como el valor que contiene), (3) la ventana de detalles: ventana empleada para revisar el historial de programación) y (4) ventana de carpeta actual: ventana empleada para ver qué archivos están contenidos en la carpeta de trabajo). En la Figura 2.9 se muestra la ventana principal del MATLAB con sus sub-ventanas.



**Figura 2.9.** Pantalla principal del MATLAB (Autoría propia).

## 2.2.2. Transformada Wavelet

La transformada wavelet (WT por sus siglas en inglés *Wavelet Transform*) es un algoritmo eficiente para el análisis de señales no-estacionarias (señales que varían sus características a lo largo del tiempo), encontrando una gran aceptación para el análisis de señales electrocardiográficas, sísmicas, de sonido, de radar, así como también es utilizada para la compresión y procesamiento de imágenes y reconocimiento de patrones (Cortés *et al.*, 2007). En la transformada wavelet, la señal es descompuesta en un número de nivel tiempo-frecuencia, donde cada nivel contiene una aproximación (filtro pasa bajas) y un detalle (filtro pasa altas) (Sheng, 1996).

Principalmente existen dos tipos de transformadas wavelets empleadas para el análisis de señales en el dominio del tiempo: (1) la transformada wavelet discreta (DWT por sus siglas en inglés *Discrete Wavelet Transform*) y (2) la transformada wavelet de paquetes (WPT por sus siglas en inglés *Wavelet Packet Transform*), las cuales serán descritas en las siguientes secciones.

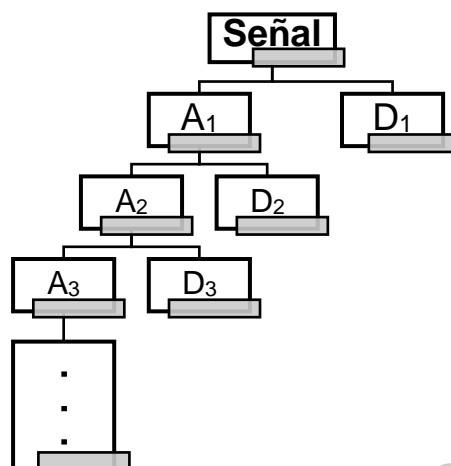
### a. Transformada Wavelet discreta

La DWT o análisis de multiresolución está basa en el algoritmo de Mallat, (Ver Figura 2.10), el cual describe que la señal original en tiempo en el nivel 1 es descompuesta en una aproximación (señal estimada por un filtro pasa bajas) y un detalle (señal estimada por un filtro pasa altas). La aproximación estimada en el nivel 1, es ahora descompuesta en una nueva aproximación y un nuevo detalle y así sucesivamente. Los rangos de frecuencia de cada aproximación (A) y detalle (D) de cada nivel (L) son estimados de acuerdo con las Ecuaciones (2.1) y (2.2).

$$A_L \Rightarrow \left[ 0, \frac{F_s}{2^{L+1}} \right] \quad (2.1)$$

$$D_L \Rightarrow \left[ \frac{F_s}{2^{L+1}}, \frac{F_s}{2^L} \right] \quad (2.2)$$

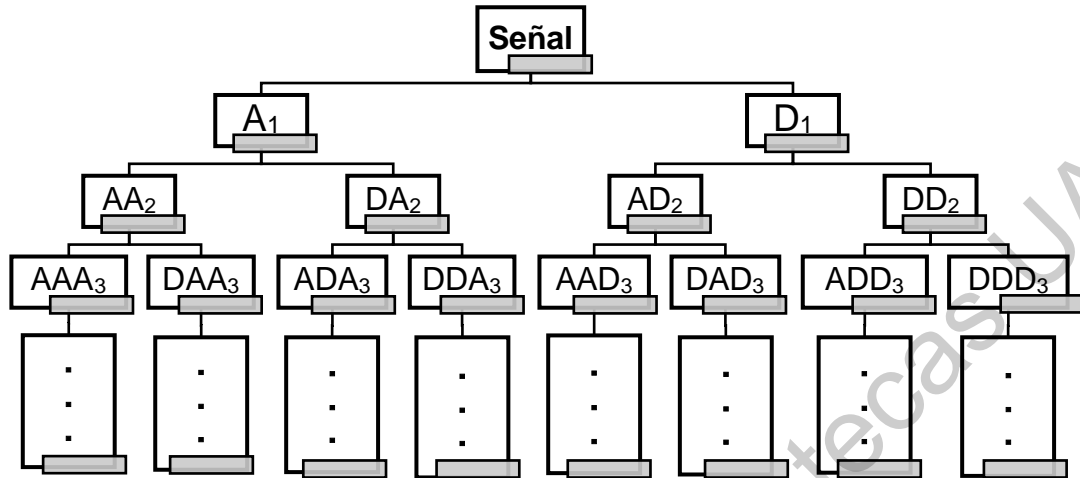
donde  $F_s$  representa la frecuencia de muestreo de la señal.



**Figura 2.10.** Estructura de descomposición de DWT (Reda *et al.*, 2006).

### **b. Transformada Wavelet de Paquetes**

A pesar de que la DWT ha sido empleada en numerosas aplicaciones (Jiménez-pinto, 2017; Amezcua-Sanchez & Adeli, 2015), en un contexto tiempo-frecuencia, esta no provee un análisis detallado de la señal, ya que solamente la aproximación obtenida del nivel 1 es descompuesta en una nueva aproximación y un nuevo detalle, lo cual significa que las frecuencias contenidas en los detalles de cada nivel no son analizadas adecuadamente. En este sentido, la WPT permite un análisis más detallado tanto de las aproximaciones y detalles estimados, ya que estos son descompuestos en una nueva aproximación y un nuevo detalle creando un árbol de frecuencias de mayor detalle (ver Figura 2.11) (Reda *et al.*, 2006). En la WPT las aproximaciones y detalles son denominados nodos de acuerdo al nivel que se esté analizando.



**Figura 2.11.** Estructura de descomposición de la WPT (Reda *et al.*, 2006).

Basado en lo antes mencionado, la WPT es capaz de proveer bandas de frecuencia (FB por sus siglas en inglés *Frequency Band*) uniformes, a diferencia de la DWT (Reda *et al.*, 2006). La WPT es definida por la Ecuación (2.3).

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

donde  $j$  representan la escalada,  $k$  la translación y  $n$  la modulación u oscilación de los parámetros.

La WPT es obtenida a través de las ecuaciones recursivas (2.4) y (2.5).

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

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

donde  $t$  es el tiempo variable,  $h(k)$  y  $g(k)$  son los coeficientes de los filtros pasa-baja (aproximaciones), pasa-altas (detalles) asociados a la función escalada y  $W^n$  es la Wavelet madre. En el presente trabajo se utilizará como Wavelet Madre la ondoleta de Daubechies 44 (db44), esta es una función de soporte compacta que posee un atributo casi simétrico que coincide con diversas bioseñales tales como EEG, ECG, EMG, VPA entre otras. En este sentido, la mayoría de las bioseñales



poseen picos agudos y asimétricos que se pueden ver captados correctamente por db44 (Rafiee et al., 2011), debido a esto la Wavelet madre db44 ha sido ampliamente usada en el procesamiento de bioseñales.

### 2.2.3. Dimensión Fractal

El término dimensión fractal (FD por sus siglas en inglés *Fractal Dimension*), fue propuesto por Mandelbrot (1983), el cual se aplica a objetos en el espacio o a fluctuaciones en el tiempo que poseen una forma de auto similitud y no pueden ser descritas en una sola escala de medida absoluta. En este sentido, FD se encarga de estudiar el grado de regularidad de una señal en función del tiempo. Los valores que puede tomar la dimensión fractal de una señal en tiempo están dentro del intervalo 1 a 2, ocurriendo el primero cuando hay poca autosimilitud dentro de la señal, y el segundo, cuando los patrones se repiten frecuentemente (Amezquita-Sanchez et al., 2017).

A lo largo de los años se han propuesto diversos algoritmos para calcular la dimensión fractal de una señal, para la presente tesis serán investigados los siguientes: Katz (KFD por sus siglas en inglés *Katz Fractal Dimension*) (Katz, 1988), Higuchi (HFD por sus siglas en inglés *Higuchi Fractal Dimension*) (Higuchi, 1988), Sevcik (SFD por sus siglas en inglés *Sevcik Fractal Dimension*) (Sevcik, 1998), Petrosian (PFD por sus siglas en inglés *Petrosian Fractal Dimension*) (Petrosian, 1995) y dimensión de conteo de cajas (BCD por sus siglas en inglés *Box Counting Dimension*) (Wang, 2005), mismos que se describen de manera más detallada a continuación:

#### a. Algoritmo de Katz

El cálculo de la dimensión fractal propuesta por Katz (1988) se describe como la proporción de la longitud de la curva  $L$ , la cual es la suma de las distancias Euclidianas entre dos puntos sucesivos, dividida por la distancia máxima  $d$  del primero punto de la señal con respecto de los demás (Katz, 1988). Se puede

interpretar como la relación de la longitud total de la curva en comparación con la línea recta correspondiente a la distancia Euclidiana máxima desde el primer punto. El Algoritmo de Katz se define como:

$$KFD = \frac{(L)}{(d)} \quad (2.6)$$

donde  $L$  es la longitud total de la curva o la suma de las distancias euclidianas entre puntos sucesivos esta se expresa en la Ecuación (2.7) y  $d$  es el diámetro (extensión planar) de la curva puede ser expresado de acuerdo con la Ecuación (2.8).

$$L = \sum_{i=1}^N dist(S_i, S_{i+1}), i = 1, \dots, N - 1 \quad (2.7)$$

$$d = \max\{dist(S_1, S_i), i = 1, \dots, N\} \quad (2.8)$$

donde  $N$  es el número de pasos en la curva. De esta manera la Ecuación (2.8) se convierte en:

$$KFD = \frac{\left(\frac{L}{a}\right)}{\left(\frac{d}{a}\right)} = \frac{(N)}{\left(\frac{d}{L}\right) + (N)} \quad (2.9)$$

donde  $a = \frac{L}{N}$

### b. Algoritmo de Higuchi

La fractalidad de una señal en tiempo empleado la dimensión fractal de Higuchi (Higuchi, 1988) se estima de acuerdo a los pasos siguientes. Primeramente, se definen nuevas series temporales a partir de un vector  $x$  de tamaño  $N$  tal que:

$$X_m^k = \left[ x_m + x_{m+k} + x_{m+2k} + \dots + x_{m+\left[\frac{N-m}{k}\right]} \right] \times m = ,1,2, \dots, k \quad (2.10)$$

donde  $k$  es el retardo entre muestras sucesivas y  $m$  es el tiempo o punto de muestreo inicial.

Posteriormente, se calcula el promedio normalizado para cada secuencia  $X_m^k$  de acuerdo a:

$$L(X_m^k) = \left( \frac{N-1}{Mk} \sum_{i=1}^M |X_m^k[i] - X_m^k[i-1]|/k \right) \quad (2.11)$$

donde  $M$  es un factor de normalización definido como:

$$M = \frac{N-m}{K} \quad (2.12)$$

A continuación, se obtiene la longitud total,  $L(k)$  de la siguiente manera:

$$L(k) = \sum_{m=1}^k L_m(k) \quad (2.13)$$

En seguida, se incrementa en una unidad el valor de  $k$ . Si se cumple la condición:  $k < k_{max}$ , se repiten los pasos previos. Esta variable del salto máximo entre muestras,  $k_{max}$ , se refiere al valor que toma  $k$  cuando la pendiente de la línea que mejor se ajusta al plano ( $\ln[L(k)]$  contra  $\ln[1/k]$ ) permanece constante. Por lo tanto, dicho valor de la pendiente de esa línea representa el valor de fractalidad de la señal.

### c. Algoritmo de Sevcik

Sevcik (1998) propuso una transformación lineal doble de la curva dentro de otro espacio métrico normalizado, convirtiendo una serie de puntos  $(x_i, y_i)$ , en iguales ya que la topología de un espacio métrico no cambia bajo transformación lineal. Para esto, la normalización de las abscisas ( $x_i$ ) y las ordenadas ( $y_i$ ) se hace de acuerdo con las Ecuaciones (2.14) y (2.15), respectivamente.

$$x_i^* = \frac{x_i}{x_{max}} \quad (2.14)$$

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

donde  $i = 1, 2, \dots, N$ ,  $x_{max} = \max(x_i)$ ,  $y_{max} = \max(y_i)$ ,  $y_{min} = \min(y_i)$ .

Una vez normalizados los valores de la señal en tiempo, se procede a calcular de distancia Euclidiana  $L$  de la siguiente manera:

$$L = \sum_{l=0}^{N-2} \sqrt{(y_{i+1}^* - y_i^*)^2 + (x_{i+1}^* - x_i^*)^2} \quad (2.16)$$

Finalmente, la fractalidad de la señal se calcula como sigue:

$$SFD = \left[ -\frac{\log \log (L) (2)}{\log \log (2(N-1))} \right] \quad (2.17)$$

donde  $D_s$  es la dimensión fractal de Sevcik y la aproximación mejora a medida que  $N \rightarrow \infty$  y/o presenta una gran cantidad de datos.

#### d. Algoritmo de Petrosian

El algoritmo de Petrosian (1995) es utilizado para proporcionar un cálculo rápido de la FD de una señal, traduciendo está a una secuencia binaria, para esto se toma en primer lugar, la serie de tiempo  $x(1), x(2), \dots, x(N)$ . Supóngase que la señal de forma de onda consiste en una serie de puntos  $\{y_1, y_2, \dots, y_N\}$ , se binariza la secuencia primero y luego se establece la matriz binaria  $z_i$  dada por la Ecuación (2.18).

$$z_i = \{1, \quad x_i > \text{mean}(y) - 1, \quad x_i \leq \text{mean}(y)\} \quad (2.18)$$

donde  $i = 1, 2, \dots, N$ .

Posteriormente, se estima el número total de cambios de símbolos adyacentes en la secuencia de la siguiente forma:

$$N_{\Delta} = \sum_{i=1}^{N-2} \left| \frac{z_{i+1} - z_i}{2} \right| \quad (2.19)$$

Finalmente, la dimensión fractal de Petrosian se estima de acuerdo a la Ecuación (2.20).

$$PFD = \frac{N}{N + \left( \frac{N}{N + 0.4N_{\Delta}} \right)} \quad (2.20)$$

## e. Conteo de cajas

Este algoritmo se basa en un cociente de logaritmos. Específicamente, se determina como el logaritmo natural de la sumatoria de las diferencias entre dos puntos consecutivos de una señal  $x(t)$  en un cierto intervalo de tiempo, dividido por el logaritmo natural del periodo de tiempo establecido (Wang, 2005). La dimensión de conteo de cajas (BCD) de una señal es definida por:

$$BCD \cong - \frac{\ln \ln \left[ \sum_{i=1}^{N-1} \frac{|x_{i+1} - x_i|}{\Delta t} \right]}{\ln \ln (\Delta t)} \quad (2.21)$$

donde  $N$  es el número de muestras de la señal de la serie temporal  $x$  para analizar y  $\Delta t$  es el intervalo de tiempo de muestreo.

### 2.2.4. Indicadores estadísticos

Los indicadores estadísticos en tiempo (STFs por sus siglas en inglés *Statistical Time Features*) son capaces de medir cambios en las propiedades de señales no estacionarias como su dispersión, asimetría, convergencia entre otros (Yanez *et al.*, 2020; Caesarendra y Tjahjowidodo, 2017), se caracterizan por ser algoritmos de baja carga computacional, debido a que no se realiza una transformación de la señal para estimar las características (Abdullah, 2005). Por esta razón, los indicadores estadísticos han sido empleados satisfactoriamente en estrategias de condición de monitoreo y diagnóstico de fallas (Delgado-Prieto *et al.*, 2013; Igba *et al.*, 2016), distinción entre las diferentes fases de la demencia (Ieracitano *et al.*, 2019), de igual modo han demostrado ser eficientes para detectar cambios en las señales asociadas a enfermedades neurodegenerativas y cardíacas (Ghorbani *et al.*, 2016; Hassan y Bhuiyan, 2016), entre otras aplicaciones. Las ecuaciones de los indicadores estadísticos empleados en el presente trabajo se describen a continuación (Abdullah, 2005; Devore y Berk, 2013; Palaniswamy y Palaniswam, 2005; Amezquita-Sanchez y Adeli, 2019):

$$\text{Media cuadrática} = \text{RMS} = \left( \frac{1}{n} \sum_{j=1}^n x_j^2 \right)^{\frac{1}{2}} \quad (2.22)$$

$$\text{Media de la raíz cuadrada} = \text{SMR} = \left( \frac{1}{n} \sum_{j=1}^n x_j^{\frac{1}{2}} \right)^2 \quad (2.23)$$

$$\text{Factor forma de RMS} = \text{Ffrms} = \frac{\text{RMS}}{\frac{1}{n} \sum_{j=1}^n |x_j|} \quad (2.24)$$

$$\text{Factor forma SMR} = \text{Ffsmr} = \frac{\text{SRM}}{\frac{1}{n} \sum_{j=1}^n |x_j|} \quad (2.25)$$

$$\text{Factor Cresta} = \text{FC} = \left| \frac{x_{j \max}}{\text{RMS}} \right| \quad (2.26)$$

$$\text{Factor Impulso} = \text{FI} = \frac{x_{j \max}}{\frac{1}{n} \sum_{j=1}^n |x_j|} \quad (2.27)$$

$$\text{Factor Latitud} = \text{FL} = \left| \frac{x_{j \max}}{\text{SRM}} \right| \quad (2.28)$$

$$\text{Media} = M = \frac{1}{n} \sum_{j=1}^n x_j \quad (2.29)$$

$$\text{Oblicuidad} = \text{Ob} = \frac{1}{n(\text{RMS})^3} \sum_{j=1}^n (x_j - M)^3 \quad (2.30)$$

$$\text{Kurtosis} = k = \frac{1}{n(\text{RMS})^4} \sum_{j=1}^n (x_j - M)^4 \quad (2.31)$$

$$5^{\text{th}} \text{ Momento} = 5M_o = \frac{1}{n(\text{RMS})^5} \sum_{j=1}^n (x_j - M)^5 \quad (2.32)$$

$$6^{\text{th}} \text{ Momento} = 6M_o = \frac{1}{n(\text{RMS})^6} \sum_{j=1}^n (x_j - M)^6 \quad (2.33)$$

$$\text{Rango} = R = x_{j \max} - x_{j \min} \quad (2.34)$$

$$\text{Varianza} = \text{Var} = \frac{1}{n} \sum_{j=1}^n (x_j - M)^2 \quad (2.35)$$

$$\text{Desviación estándar} = \text{Des} = (\text{Var})^{\frac{1}{2}} \quad (2.36)$$

$$\text{Mediana} = \text{Me} = \begin{cases} x_{\left(\frac{n+1}{2}\right)}, & n = \text{numero impar} \\ \frac{1}{2} \left( x_{\left(\frac{n}{2}\right)} + x_{\left(\frac{n}{2}+1\right)} \right), & n = \text{numero par} \end{cases} \quad (2.37)$$

$$\text{Moda} = Md = L_i + c \frac{d^-}{d^- + d^+} \quad (2.38)$$

$$\text{Energía} = E = \sum_{j=1}^n |x_j|^2 \quad (2.39)$$

donde  $x_j$  es la  $j$ -ésima muestra de la serie temporal que va de  $j = 1, 2, 3 \dots n$ ,  $n$  es el número de muestras,  $L_i$  es el límite inferior de la clase modal,  $c$  es el ancho de la clase modal,  $d^-$  y  $d^+$  son las diferencias absolutas del intervalo modal y las clases de los intervalos vecinos, respectivamente.

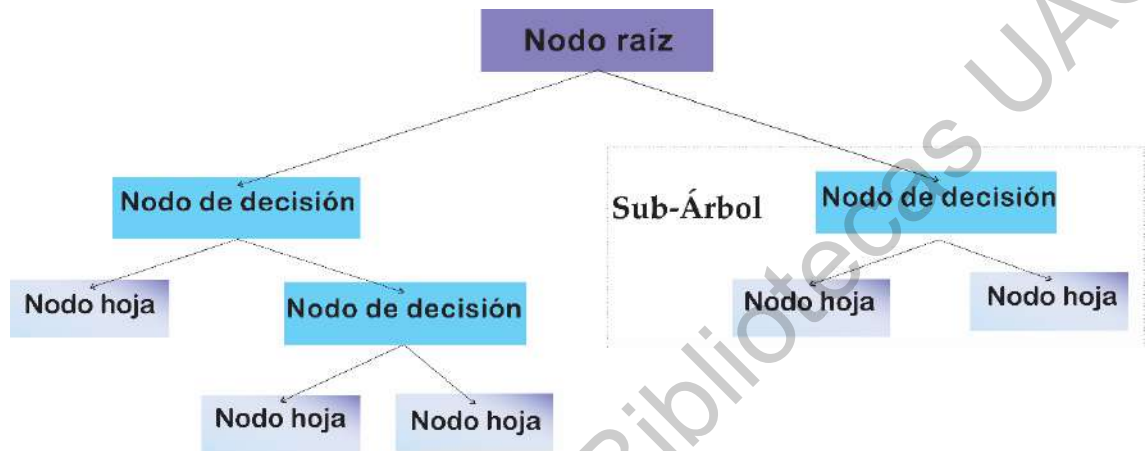
### 2.2.5. Método de Kruskal-Wallis

El método de Kruskal-Wallis es un método no paramétrico utilizado para evaluar la independencia estadística de señales con distribución normal o no normal (Kruskal y Wallis, 1952). Este método evalúa las medianas de los grupos de características mediante una hipótesis nula que consiste en asumir que todas las medianas de los conjuntos de datos son iguales (Hecke, 2012). Si el valor de probabilidad (valor  $P$ ) es menor que un rango entre 0.05 y 0.01 (Hecke, 2012), se rechaza la hipótesis nula, lo que indica que las características para diferenciar entre un conjunto de datos seleccionado y los conjuntos de datos restantes pueden usarse de manera segura. Por el contrario, si el valor  $P$  es mayor que el rango antes mencionado (Hecke, 2012), se acepta la hipótesis nula; esto significa que los grupos de características tienen información similar y no se pueden usar para determinar las diferencias entre los grupos. Por lo tanto, el valor  $P$  se usa para determinar los indicadores más discriminatorios para predecir una convulsión.

### 2.2.6. Clasificador basado en árbol de decisión

El clasificador de árbol de decisión (DTC por sus siglas en inglés *Decision Tree Classifier*) es un clasificador simple pero efectivo que ofrece una implementación fácil y flexible ya que puede implementarse usando un conjunto de reglas if-else con una carga computacional baja (Nisbet *et al.*, 2018; Ardhapure *et*

al.,2016). Este tipo de clasificador presenta una buena precisión de clasificación asumiendo que los conjuntos de características no se superponen en gran medida (Shobha y Rangaswamy, 2018; Jukic *et al.*, 2018). La Figura 2.12 muestra una ilustración gráfica de un DTC.



**Figura 2.12.** Descripción general del árbol de decisiones (Shobha y Rangaswamy, 2018).

El procedimiento utilizado para crear un árbol de decisión es (Rasoul y Landgrebe,1990):

- Selección de nodos de división de reglas.
- Conjunto de los nodos terminales.
- Asignación de la etiqueta de clase correspondiente a los nodos terminales.

La decisión en cada etapa del árbol depende de las operaciones de ramificación anteriores. La estructura del árbol (ver Figura 2.12) comienza con el nodo raíz, luego realiza la prueba que sigue al borde y luego repite la prueba hasta que alcanza el nodo final (hoja) (Shobha y Rangaswamy, 2018). Una vez que llega al nodo hoja, el árbol predice el resultado asociado, es decir, la etiqueta de clase (Wei *et al.*, 2020). Este procedimiento que se lleva a cabo en un DTC se resume a continuación (Polat y Günes,2007):



- Diseño de una prueba lógica para cada característica que se utilizará como entrada al DTC.
- Para cada prueba lógica, se crea un subconjunto de los datos de entrenamiento para verificar que el resultado al nodo terminal correspondiente asigna la etiqueta esperada.
- El proceso se repite para todos los nodos, hasta llegar al nodo terminal.

Dirección General de Bibliotecas UAO

# Capítulo 3

## 3. Metodología

En este apartado se presenta la metodología propuesta para el desarrollo del presente trabajo. La Figura 3.1. resume de manera gráfica la metodología para el desarrollo de este trabajo de tesis, el cual consta de cinco pasos para predecir una crisis epiléptica.

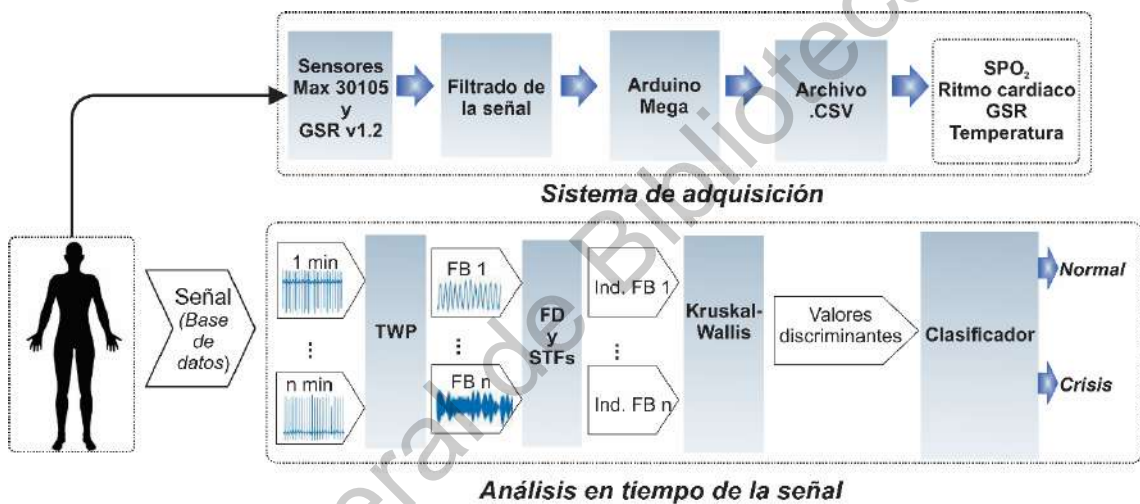


Figura 3.1. Diagrama a bloques de la metodología de investigación propuesta (Autoría propia).

### Sistema de adquisición

- **Paso 1: Sensores.** Las señales provenientes del cuerpo humano son adquiridas mediante los sensores Max 30105 y GSR v 1.2, estos son los encargados de convertir las señales provenientes del cuerpo en una señal analógica en una que pueda ser procesada por el sistema.
- **Paso 2: Acondicionamiento de la señal.** Una vez adquirida las señales provenientes del cuerpo, estas son filtradas con la finalidad de eliminar en la

medida de lo posible. De igual manera se realiza un acondicionamiento de la señal desde el diseño de los recipientes de los sensores.

- **Paso 3: Tarjeta de adquisición.** Es la encargada de realizar la interfaz que permitirá transformar los datos de analógicos en códigos digitales. Para esto se encarga de pedirle a los sensores los datos con cierta frecuencia de muestreo, posteriormente mediante un código establecido se encargará de convertirlos los datos provenientes de los sensores en las medidas requeridas y estas enviarlas a un sistema de almacenamiento de datos.
- **Paso 4: Almacenamiento de datos.** Finalmente, los datos obtenidos serán almacenados en un archivo .CSV, el cual tendrá 4 columnas por n cantidad de filas (estas dependen del tiempo muestreado).

#### **Análisis en tiempo de la señal**

- **Paso 1: Preprocesamiento.** Las señales ECG proporcionadas por la base de datos del Instituto de Tecnología de Massachusetts-Beth Israel Hospital (MIT-BIH), disponibles en (<https://www.physionet.org/physiobank/database/szdb/>), son descompuestas en diferentes bandas de frecuencia haciendo uso de la transformada Wavelet de paquetes con el fin de dividir el ruido e identificar con mayor certeza las características relacionadas con un posible evento epiléptico.
- **Paso 2: Procesamiento.** Una vez descompuesta las señales en las diferentes bandas de frecuencia haciendo uso de la transformada wavelet de paquetes, estas bandas de frecuencia son analizadas por diferentes indicadores no lineales como dimensión fractal (algoritmos evaluados: Katz, Higuchi, Petrosian, Sevcik y dimensión de caja) e indicador-es estadísticos (por ejemplo: factor cresta, energía, etc) con el fin de identificar patrones o características que puedan ser asociadas al fenómeno estudiado
- **Paso 3: Análisis estadístico.** Los diversos valores de los indicadores no lineales estimados para las bandas de frecuencia son evaluados a través de

un análisis estadístico, con el fin de determinar cuál(es) banda(s) e indicadores(s) son los más útiles para determinar entre una persona sana y una que va a sufrir una crisis epiléptica.

- **Paso 4: Clasificador.** Finalmente, una vez seleccionados la(s) banda(s) e índice(s) no lineales más discriminativos por medio del análisis estadístico, estos son empleados para entrenar y validar un clasificador con el fin de poder predecir un evento o crisis epiléptica de forma automática.

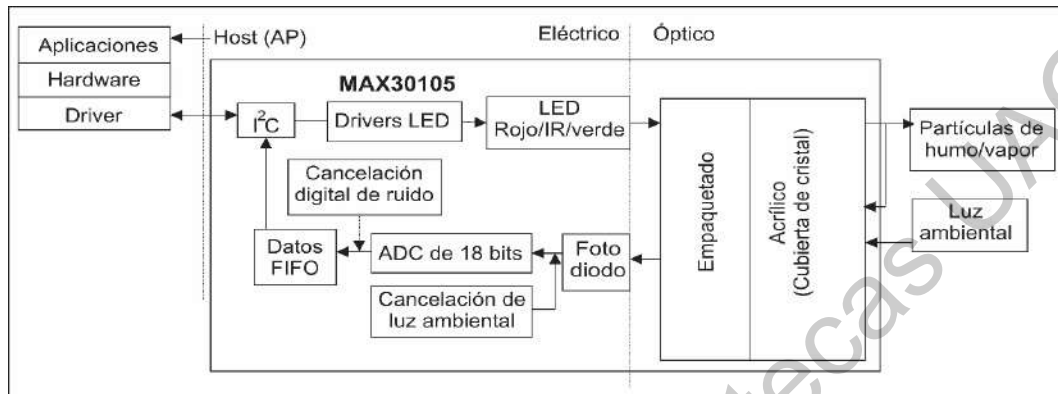
### 3.1. Sistema de adquisición

El sistema de adquisición propuesto en este trabajo de tesis se basa en 2 etapas principales: sensores y acondicionamiento de la señal y tarjeta de adquisición de datos y almacenamiento del sistema de adquisición, los cuales son descritos a detalles en las siguientes subsecciones.

#### 3.1.1 Sensores y acondicionamiento de las señales

Con el fin de poder medir los biopotenciales tales como frecuencia cardiaca, oxigenación en sangre y la actividad electrodérmica de una persona se emplean diversos sensores. En este sentido, el sensor óptico de partículas modelo Max30105 fabricado por Maxim Integrated es empleado para monitorear la frecuencia cardiaca y la oxigenación en la sangre. Para realizar estas tareas, este sensor monitorear los cambios en el volumen de sangre en el tejido (dedo) mediante el uso de emisiones de luz con dos longitudes de onda 660nm (roja) y 990 nm (infrarrojo) que son características de la oxihemoglobina y la desoxihemoglobina (Hu *et al*, 2013). Para su funcionamiento, el sensor Max30105 cuenta con un arreglo óptico reflectivo (ver Figura 3.2), en donde un led rojo y otro infrarrojo se iluminan alternadamente, de este modo la luz que no es absorbida por el tejido se refleja y se mezcla con la luz ambiental, obteniendo la medida final que es detectada por el fotodiodo, posteriormente la señal obtenida por el fotodiodo pasa un bloque de cancelación de luz ambiental para después ser digitalizada por un convertidor analógico digital de 18 bits. A continuación, la señal digital pasa a un sistema de cancelación de ruido,

después se almacenan los datos en registro FIFO y finalmente se transmiten los datos mediante un protocolo  $i^2C$ .



**Figura 3.2.** Diagrama del sensor Max30105 (Maxim integrated, 2016).

Al monitorear las señales empleando este tipo de sensor, se debe tener especial cuidado con la luz que pasa durante la toma de muestra ya que los resultados pueden ser alterados principalmente por la luz exterior (Rojas-Pérez, 2006). En este sentido, para evitar este problema se diseñó un capuchón (ver Figura 3.3), el cual cubre al dedo y al sensor, el diseño está realizado en forma de pinza para que se realice presión y evitar el ingreso de la luz, este diseño fue realizado en un software de diseño 3D (Figura 3.3a) y fue impreso en una impresora 3D (Figura 3.3b).

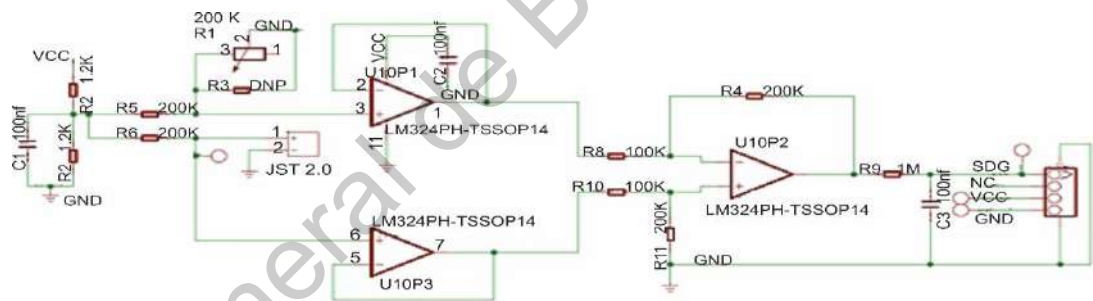


**Figura 3.3.** Diseño del capuchón del sensor de frecuencia cardiaca y oxigenación en sangre (a) diseño virtual, (b) diseño creado (Autoría propia).

Por otro lado, para la medición de la actividad electrodérmica de una persona se utiliza el sensor modelo GSR v.1.2 fabricado por SeedStudio. Este sensor consiste en 2 electrodos conectados con un módulo de acondicionamiento, el cual se observa en la Figura 3.4. Este módulo proporciona información de la resistencia de la piel del paciente censado. Para obtener estos valores de resistencia ( $\Omega$ ), es necesario aplicar la siguiente ecuación (SeedStudio,2014):

$$Resistencia = \frac{(1024 + 2 * valor\ medido) * 10000}{512 - valor\ medido} \quad (3.1)$$

Este valor de resistencia es el mostrado en el sistema de adquisición de datos. Es importante aclarar que se realizó la conversión a ohm para poder comparar con los valores establecidos en la literatura como normales para un estado de relajación.



**Figura 3.4.** Diagrama del sensor GSR v.1.2 (SeedStudio,2014).


La Tabla 3.1 muestra las principales características de los sensores utilizados.

**Tabla 3.1.** Características de los sensores Max30105 y GSR v.1.2.

Propiedad	Max 30105	GSR v.1.2
Frecuencia de Muestreo máxima	3200 Hz (Max)	---
Protocolo de comunicación	I <sup>2</sup> c	I <sup>2</sup> c
Salida	Digital (18 bits)	Resistencia (Sensibilidad variable mediante potenciómetro)
Voltaje de funcionamiento	5 V	3.3 y 5 V

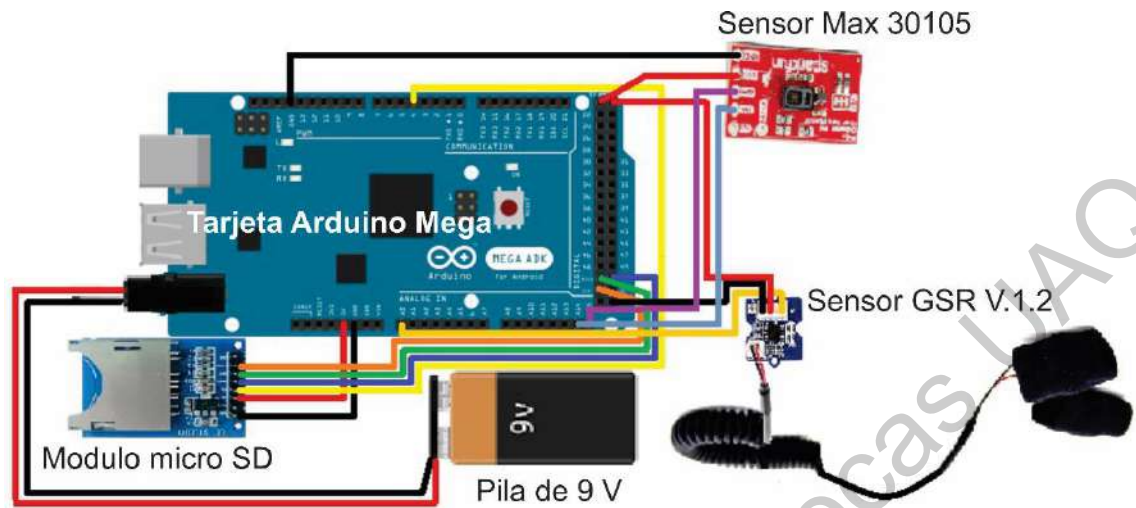
### 3.1.2 Tarjeta de adquisición de datos y control del sistema de adquisición

Con el fin de adquirir los biopotenciales de una persona y que este permita la portabilidad, se emplea una tarjeta de adquisición de la marca Arduino modelo Mega 2560 mostrada en la Figura 3.5. Esta tarjeta presenta las siguientes características: 54 pines digitales entrada/salida, de los cuales 15 se pueden usar como salidas PWM, 16 entradas analógicas, 4 UART, oscilador de 16MHz, memoria Flash de 256 KB de los cuales 8 KB son utilizados por el gestor de arranque, SRAM 8 KB y EEPROM de 4 KB (Arduino,2021).




**Figura 3.5.** Esquema de Tarjeta de adquisición Arduino Mega 2560 (Arduino,2021).

El sistema de monitoreo de los biopotenciales (ritmo cardiaco, oxigenación y electrodérmico) se desarrolló con la finalidad de ser portátil. Para cumplir con esta tarea, este sistema consta de una unidad de almacenamiento microSD donde la información proveniente de los sensores es almacenada para su posterior procesamiento; además se emplea para su alimentación una pila de 9 volts como se observa en la Figura 3.6. Adicionalmente, las conexiones que se realizan con la tarjeta de adquisición Arduino Mega se muestran en la Figura 3.6.



**Figura 3.6.** Diagrama de conexiones de sistema (Autoría propia).

La Figura 3.7 muestra el sistema completo de monitoreo desarrollado para de los diferentes biopotenciales, donde se puede observar el sensor de ritmo cardiaco, oxigenación y actividad electrodérmica



**Figura 3.7.** Sistema de monitoreo de los diferentes biopotenciales (ritmo cardiaco, oxigenación y actividad electrodérmica) (Autoría propia).

Con el fin de controlar las señales/datos provenientes de los sensores y almacenarlos, la Figura 3.8 muestra primeramente la declaración de las librerías a usar, los tipos de datos y la definición de los puertos a usar, posteriormente se



muestra el código para abrir un archivo en la micro SD del tipo valores separados por comas (CSV por sus siglas en inglés *Comma Separated Values*), en este tipo de archivo los caracteres están separados por comas, realizando una tabla en filas y columnas. Las columnas son definidas por cada coma, mientras que cada fila se define mediante una línea adicional de texto. Este tipo archivo se identifica con el programa Excel.

```

#include <Wire.h>
#include "MAX30105.h"
#include "spo2_algorithm.h"
#include <SD.h>
MAX30105 particleSensor;

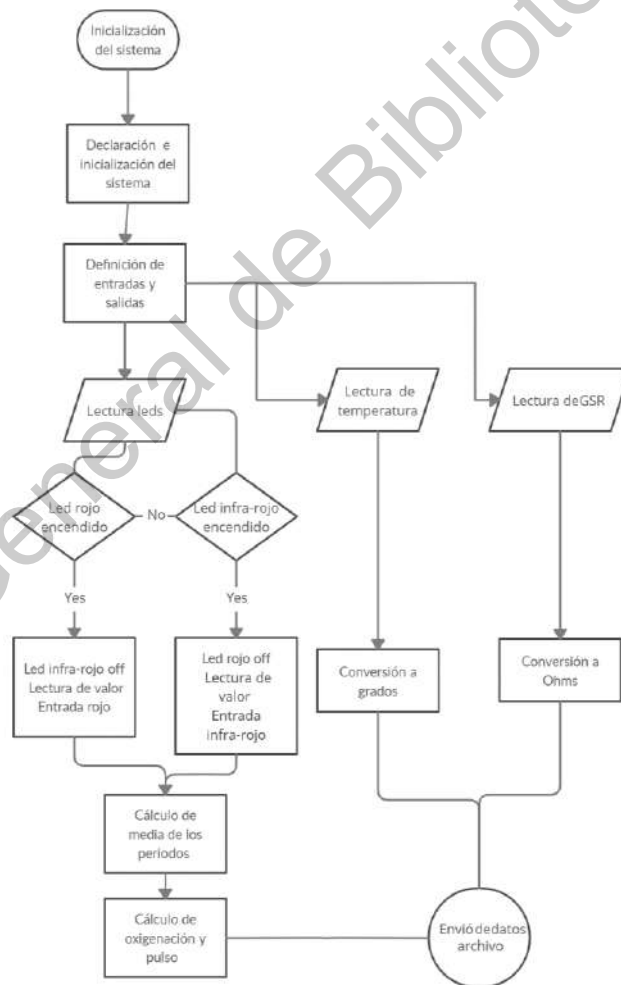
//variable sd
File myFile;
//Variables spo2, gsr
#define MAX_BRIGHTNESS 255
uint16_t irBuffer[100]; //datos infrarrojo
uint16_t redBuffer[100]; //datos rojo
int32_t bufferLength; //datos
int32_t spo2; //Saturación oxígeno
int8_t validSPO2; //validación saturacion
int32_t heartRate; //valor ritmo cardiaco
int8_t validHeartRate; //validación ritmo cardiaco
//variables GSR
int GSR=Al; //conexión Al de arduino
int sensorValue=0;
int gsr_average=0;0
int gsr_ohm=0;
// variables temperatura
float temperature=0;

void setup()
{
  Serial.begin(115200); // iniciar comunicación serial
  //iniciar sd
  !SD.begin(4);
  if(!SD.exists("dato.csv"))
  {
    myFile = SD.open("dato.csv", FILE_WRITE);
    if (myFile)
    {
      myFile.println("Temperatura °C, Ritmo cardiaco,SPO2,GSR");
      myFile.close();
    }
  }
}

```

**Figura 3.8.** Impresión de pantalla de código de lectura y apertura de archivo tipo .CSV (Autoría propia).

Posteriormente dentro del bucle de Arduino se realiza el cálculo de la saturación en sangre, ritmo cardíaco, GSR y temperatura, esto siguiendo los pasos mostrados en el diagrama de flujo de la Figura 3.9, en el bloque correspondiente a la lectura de los leds con la finalidad determinar el rango de la señal se leen los primeros 100 datos y posteriormente se procede a realizar el cálculo de oxigenación en sangre y ritmo cardíaco, los valores de estos se calculan con la media de cada 25 muestras. El valor de la respuesta galvánica es calculado mediante la ecuación 3.1, con la finalidad de evitar errores en la medida de lo posible se el valor se calcula a partir del promedio de 10 muestras.



**Figura 3.9.** Diagrama de flujo del sistema (Autoría propia).

Finalmente, los datos obtenidos de cada medida (ritmo cardiaco, oxigenación en sangre, temperatura y respuesta galvánica de la piel), son enviados al archivo .CSV que fue abierto y asignados a una columna específica. Cuando el envío de los datos se ha finalizado el archivo es cerrado (ver Figura 3.10) y queda almacenado en la micro SD, para su posterior visualización.

```
myFile.print(heartRate, DEC);  
myFile.print(",");  
myFile.print(spo2, DEC);  
myFile.print(",");  
myFile.print(temperature);  
myFile.print(",");  
myFile.println(gsr_ohm);  
  
myFile.close(); //se cierra el archivo  
}  
}
```

**Figura 3.10.** Almacenamiento de los valores obtenidos en el archivo tipo .CSV (Autoría propia).

## 3.2. Materiales

A causa de la contingencia sanitaria por COVID-19 y a fin de salvaguardar la salud del paciente con epilepsia, el paciente no será monitoreado por el sistema de adquisición desarrollado; sin embargo, el funcionamiento del sistema de adquisición de señales propuesto originalmente si será validado mediante la toma de muestras de sujetos sanos. Por otro lado, la validación de la metodología propuesta se utilizará una base de datos de señales de ECG generada con pacientes que sufren de crisis epilépticas. En las siguientes secciones se explica de manera más detallada cada uno de los recursos utilizados.

### 3.2.1. Recursos humanos

Con la finalidad de validar el funcionamiento del sistema de monitoreo desarrollado, 5 pacientes fueron monitoreados. La adquisición de señales en cada

paciente se realizó con base en los principios éticos dados por el consejo de organizaciones internacionales de las ciencias médicas (CIOMS por sus siglas en inglés *Council for International Organizations of Medical Sciences*) en colaboración con la Organización Mundial de la Salud (CIOMS & OMS, 2017). Es importante mencionar que la toma de muestra se realizó siguiendo las normas de seguridad e higiene derivadas de la situación actual. A cada paciente se le explicó en qué consistía la toma de muestra y se le dio una carta de consentimiento informado por escrito y una carta de confidencialidad de datos los cuales se muestra en los anexos 1 y 2.

Se recolectaron 2 señales digitales de cada biopotencial (oxigenación en sangre, ritmo cardíaco, temperatura y respuesta galvánica de la piel) por paciente. El tiempo de registro de las señales fue de 5 minutos, con una frecuencia de muestreo de 1000. La muestra evaluada consistió de 5 individuos (2 mujeres y 3 hombres, cuyo rango de edad varía entre 20 y 55 años de edad).

### **3.2.2. Base de datos**

Con la finalidad de validar la metodología propuesta en el presente trabajo de tesis, se analizó la base de datos titulada “Post-Ictal Heart Rate Oscillations in Partial Epilepsy” (MIT/BIH-PIHROPE, 2018) la cual incluye 7 señales ECG, donde se registraron 10 crisis epilépticas en los siete pacientes con edades entre los 31 y 48 años. Es importante mencionar que los pacientes con crisis epilépticas no tenían evidencia clínica de enfermedad cardíaca y presentaban crisis parciales con o sin generalización secundaria de focos frontales o temporales. La adquisición de los datos se hizo bajo un protocolo aprobado por el Comité de Investigaciones Clínicas del Beth Israel Deaconess Medical Center. (Al-Aweel, *et al.* 1999).

Adicionalmente, las crisis epilépticas presentaron una duración aproximada de entre 15 a 110 segundos (tres de los sujetos tuvieron múltiples crisis registradas). El aumento en la frecuencia cardíaca durante las convulsiones varió de 28 a 88

latidos por minuto (lpm) para los eventos con oscilaciones post-ictales ( $n = 5$ ), y de 3 a 68 lpm para aquellas convulsiones sin las oscilaciones ( $n = 5$ ). Los pacientes con y sin oscilaciones estaban dormidos o descansando en silencio antes de las convulsiones. (Al-Aweel, *et al.* 1999). La Tabla 3.2 presenta el inicio en tiempo de los eventos epilépticos encontrados en las señales ECG (Al-Aweel, *et al.* 1999).

**Tabla 3.2.** Registro en tiempo de las crisis epilépticas presentadas durante el estudio de ECG.

No. Paciente	Inicio de evento epiléptico a partir del inicio de toma de ECG (horas: minutos: segundos)	Fin de evento epiléptico a partir del inicio de toma de ECG (horas: minutos: segundos)
1	00:14:36	00:16:12
2	01:02:43	01:03:43
	02:55:51	02:56:16
3	01:24:34	01:26:22
	02:34:27	02:36:17
4	00:20:10	00:21:55
5	00:24:07	00:25:30
6	00:51:25	00:52:19
	02:04:45	02:06:10
7	01:08:02	01:09:31

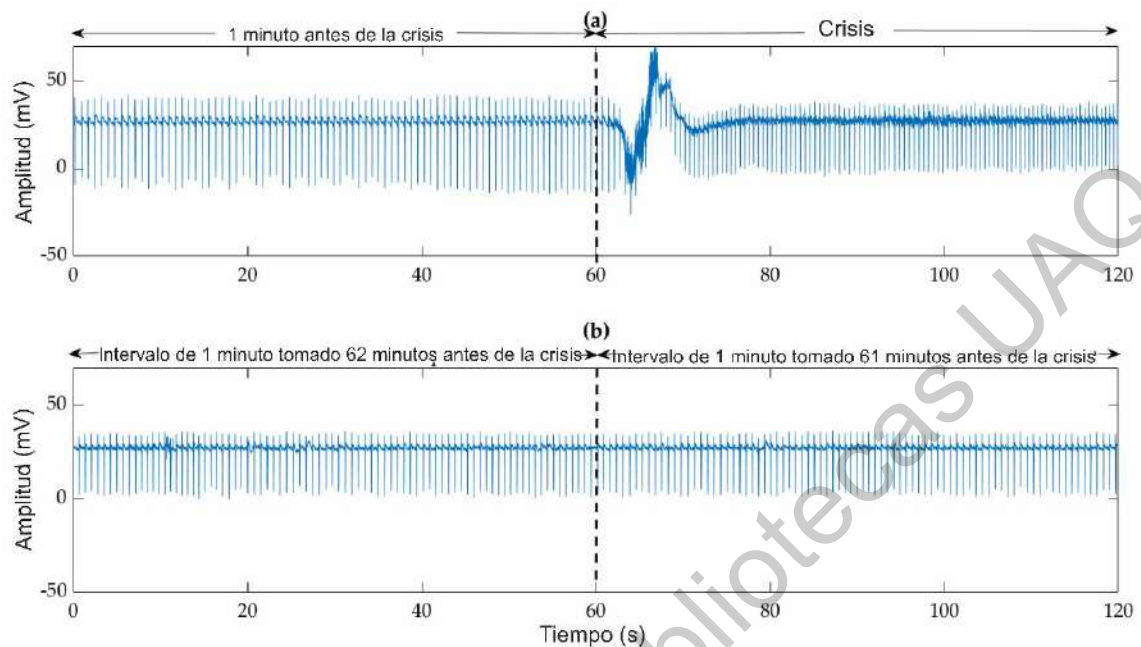
### 3.2.3. Preparación de las señales ECG de la base de datos

Las señales ECG fueron monitoreadas durante 3 horas empleando una frecuencia de muestreo de 200 Hz (Al-Aweel, *et al.* 1999). Sin embargo, las señales fueron diezmadas de 200 Hz a 128 Hz, ya que este valor de frecuencia de muestreo ha demostrado ser adecuada para encontrar enfermedades en el corazón (Vargas-Lopez *et al.*, 2020; Fujita *et al.*, 2016; Amezcua-Sanchez *et al.*, 2018; Nahak y Saha, 2020) y permite reducir la cantidad de información para procesar. El proceso de diezmado es llevado a cabo convolucionando la señal ECG con un filtro pasa

bajas de respuesta infinita al impulso o filtro FIR. De las 3 horas grabadas para cada paciente con crisis epilépticas, únicamente los primeros 15 minutos de la señal ECG antes del inicio de la crisis son extraídas y analizadas en este trabajo. Estos 15 minutos son segmentados en intervalos de 1 minuto; por ejemplo, el primer intervalo de 1 minuto, el segundo intervalo de 1 minuto y así sucesivamente antes de la crisis epiléptica. Cabe destacar que esta ventana de tiempo permite explorar y ofrecer una predicción de crisis epiléptica más precoz que la proporcionada por otros trabajos presentados en la literatura.

Por otro lado, se obtiene un grupo sano (GS) extrayendo intervalos de 1 minuto de las señales del ECG 1 hora antes o después de la convulsión ya que en este tiempo los pacientes presentan un ritmo cardíaco normal (Al-Aweel, *et al.* 1999). Es importante mencionar que se seleccionan las ventanas de tiempo de 1 minuto porque han permitido identificar características confiables en las señales del ECG para predecir una muerte cardíaca súbita, así como una convulsión (Vargas-Lopez *et al.*, 2020; Amezquita-Sanchez *et al.*, 2018; Nahak y Saha,2020; Chinara,2020). Por esta razón, en este trabajo también se explora el intervalo de 1 minuto para predecir una convulsión hasta 15 minutos antes del inicio.

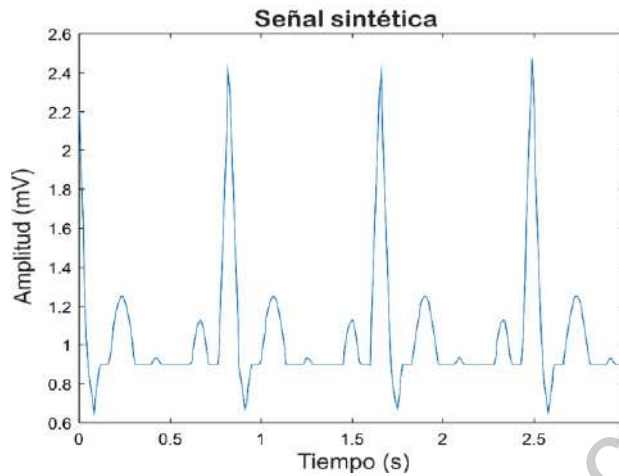
La Figura 3.11 ilustra el primer intervalo de 1 minuto de la señal de ECG antes de la crisis epiléptica y dos intervalos de 1 minuto de la señal de ECG registrados 1 hora antes de que ocurra la convulsión, respectivamente. A partir de esta figura, no es posible identificar visualmente diferencias o cambios significativos entre ambos grupos de señales de ECG antes del inicio de la convulsión. Por lo tanto, esto genera la importancia de un método/metodología capaz de identificar patrones o características en las señales que puedan ser asociados al fenómeno estudiado.



**Figura 3.11.** (a) Señal ECG un minuto antes y después de la crisis epiléptica y (b) señal ECG tomada como grupo sano (señal obtenida 1 hora antes de la aparición de una crisis epiléptica).

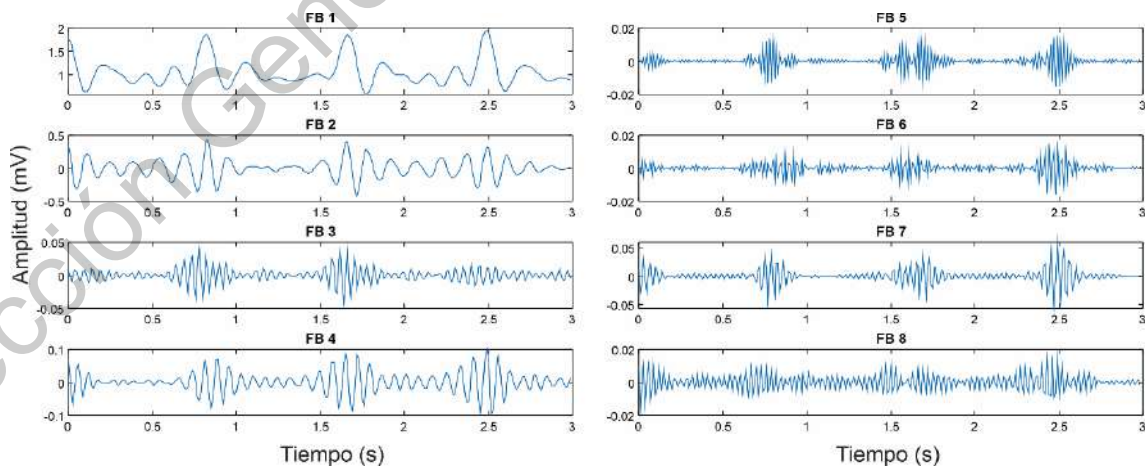
### 3.3. Procedimiento para el análisis tiempo-frecuencia de las señales

Con el propósito de ejemplificar los pasos más importantes de la metodología propuesta para predecir una crisis epiléptica, WPT e indicadores estadísticos (RMS, SMR, Factor Cresta, Factor Latitud, etc.) y fractales (Katz, Higuchi, Petrosian, Sevcik y dimensión de caja), se simula una señal ECG señal sintética que asemeja el ritmo cardíaco normal (Amezquita-Sanchez *et al.*, 2018) (ver Figura 3.12). La señal generada presenta las siguientes características: una amplitud 2.4 mV similar a las ondas adquiridas por un electrocardiograma y una frecuencia de muestreo de 100 Hz durante un tiempo de 3 s, resultando en 300 muestras como se muestra en la Figura 3.12.



**Figura 3.12.** Señal ECG sintética (Autoría propia).

Siguiendo la metodología propuesta, primeramente, la señal ECG es procesada por medio de la WPT empleando una ondoleta madre Daubechies 44 hasta un nivel 3 con el fin de ejemplificar. La Figura 3.13 muestra las 8 bandas de frecuencia (FB) estimadas en el nivel 3. Como se puede observar en esta figura, al realizar el análisis tiempo-frecuencia empleando la WPT se genera un análisis más detallado de la señal, permitiendo identificar de una forma eficiente las características que puedan estar ocultas en la señal.



**Figura 3.13.** Bandas de frecuencia obtenidas para el nivel 3 de descomposición para la señal sintética (Autoría propia).



Una vez estimadas las diferentes bandas de frecuencia por la TWP, los diferentes algoritmos de fractalidad e indicadores estadísticos, son aplicados a cada una de las descomposiciones obtenidas con el fin de obtener sus características. La Tabla 3.3 muestran los valores obtenidos de fractalidad e indicadores estadísticos para cada descomposición.

**Tabla 3.3.** Valores de indicadores no lineales, para cada una de las bandas de frecuencia (FB) de la señal sintética.

Indicador	FB 1	FB 2	FB 3	FB 4	FB 5	FB 6	FB 7	FB 8
<i>KFD</i>	1.2228	1.2256	1.0650	1.1252	1.0366	1.0272	1.086	1.0378
<i>HFD</i>	1.6251	1.8598	1.9427	1.9059	1.8430	1.9179	1.9071	1.9483
<i>SFD</i>	1.4896	1.5596	1.6581	1.6332	1.7236	1.6956	1.6404	1.7463
<i>PFD</i>	1.0044	1.0096	1.0286	1.0190	1.0579	1.0519	1.0376	1.0424
<i>BCD</i>	1.3159	1.3671	1.3455	1.3578	1.2615	1.3312	1.2258	1.6894
<i>RMS</i>	1.0834	.01436	.0102	.0311	.0044	.0037	.0127	.0048
<i>SMR</i>	1.0295	.0870	.0055	.0174	.0019	.0017	.0054	.0031
<i>Ffrms</i>	1.0354	1.3323	1.4740	1.4020	1.6561	1.5570	1.6638	1.2793
<i>Ffsmr</i>	.9840	.8073	.7886	.7828	.6956	.7415	.7129	.8557
<i>FC</i>	1.7881	3.0344	4.1431	3.1823	3.5567	4.4055	4.6759	3.4102
<i>FI</i>	1.8514	4.0428	6.1067	4.4616	5.8903	6.8595	7.7799	4.3628
<i>FL</i>	1.8815	5.0078	7.7435	5.6995	8.4676	9.2497	10.9122	5.2206
<i>M</i>	1.0463	$-3 \times 10^{-4}$	$6.8 \times 10^{-6}$	$2.7 \times 10^{-5}$	$-3.5 \times 10^{-7}$	$-1.8 \times 10^{-7}$	$-1.3 \times 10^{-5}$	$8.6 \times 10^{-8}$
<i>R</i>	1.0834	0.1436	.0102	.0311	.0044	.0037	.0127	.0048
<i>Ob</i>	1.2749	-.006	-.0017	.0086	$2.2 \times 10^{-4}$	$5.1 \times 10^{-4}$	-.0059	.300
<i>K</i>	4.6702	3.6327	6.9758	4.2050	6.4859	7.3463	8.4613	3.5840
<i>5Mo</i>	11.1358	.4310	-.0814	.0630	.0026	.8750	.0072	2.1032
<i>6Mo</i>	32.2171	19.7179	81.2022	24.9775	55.5565	93.1707	117.9096	23.4706
<i>Var</i>	.02814	.1438	.0102	.0311	.0044	.0037	.0127	.0048
<i>Des</i>	.0792	.0207	$1 \times 10^{-4}$	$9.6 \times 10^{-4}$	$1.9 \times 10^{-5}$	$1.3 \times 10^{-5}$	$1.6 \times 10^{-4}$	$2.3 \times 10^{-5}$
<i>Me</i>	.9747	.0043	$7.6 \times 10^{-5}$	$4.3 \times 10^{-5}$	$-3 \times 10^{-5}$	$-3.6 \times 10^{-5}$	$-1.4 \times 10^{-4}$	$-1 \times 10^{-4}$
<i>Md</i>	.5814	-.4146	-.0423	-.0942	-.0154	-.0157	-.0559	-.0162
<i>E</i>	3525.09	6.1857	.0313	.2899	.0059	.0040	.0481	.0069

Observando la Tabla 3.3, se aprecia que los valores de los fractales e indicadores estadísticos son distintos en cada banda de frecuencia, ya que estas representan información diferente dentro del fenómeno a analizar; por lo tanto, es importante evaluar (por ejemplo, con el método Kruskal-Wallis) cada indicador con el fin de estimar cuál de ellos es más discriminante para predecir una crisis epiléptica.

# Capítulo 4

## 4. Resultados y discusión

En este capítulo se presentan las puestas de experimento y resultados obtenidos para validar el sistema de adquisición de señales desarrollado y la metodología propuesta la predicción de crisis epilépticas, respectivamente.

### 4.1. Sistema de adquisición

#### 4.1.1 Puesta de experimento

La Figura 4.1 muestra la puesta de experimento con el fin de validar el correcto funcionamiento del sistema de adquisición desarrollado. Durante la adquisición de las señales se colocaron 2 electrodos en los dedos índice y medio, un sensor de pulso en el dedo anular del paciente (ver Figura 4.1), mientras el paciente se encontraba en estado relajación, en la otra mano se colocó un pulsioxímetro comercial y se tomó la temperatura durante 5 minutos ya que esta no presenta variaciones notorias.





Figura 4.1. Sensores colocados en el paciente (Autoría propia).

Una vez colocados los sensores, el sistema de adquisición fue encendido y la información se monitoreo durante 300 segundos con una frecuencia de muestreo de 0.1 Hz para obtener 30 datos por cada señal fisiológica medida (ver Figura 4.2), esto debido a que al tratarse de pacientes sanos en estado de relajación los valores tomados no muestran una variación significativa. Al finalizar la fase de adquisición de datos los sensores fueron sanitizados.



**Figura 4.2.** Puesta de experimento de sistema de adquisición de señales (Autoría propia).

#### 4.1.2 Resultados

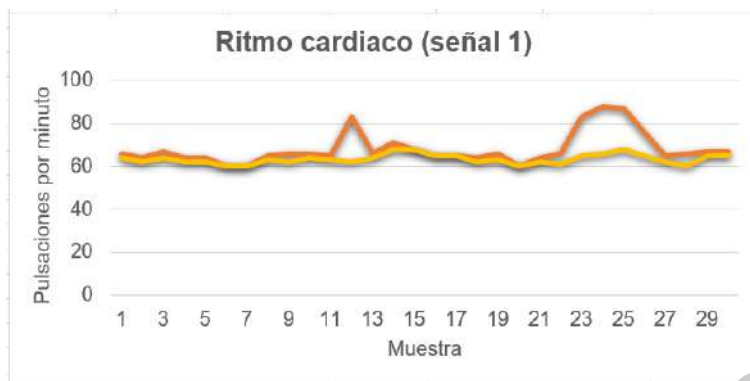
Los resultados obtenidos por el sistema desarrollado fueron comparados con equipos comerciales tales como el equipo comercial de pulsioximetría/oxigenación de la marca Uplayteck y un termómetro infrarrojo de la marca intey, esto fue realizado para cada una de las muestras adquiridas de los 5 pacientes participantes. La Figura 4.3 muestra la gráfica comparativa de las lecturas de saturación de sangre para el sistema desarrollado (línea de color gris) y el dispositivo comercial (línea de color azul). Es importante aclarar que los valores del dispositivo comercial son obtenidos mediante la toma de un video continuo. Observando esta figura, es importante mencionar que los valores de oxigenación en sangre se encuentran

dentro de los parámetros considerados para una persona sana, ya que el porcentaje de saturación en sangre en condiciones normales varía entre el 96% al 100% (AAOS y Page,2019), en cuanto a las variaciones que se presentan entre el sistema comercial y sistema de adquisición propio, estas se consideran que se deben principalmente debido al capuchón que cubre el sensor Max30105 y cuyos objetivos son impedir el paso de luz ambiental la cual afecta la medida y proporcionar un correcto posicionamiento del dedo en el sensor. Sin embargo, el sistema propio presenta resultados similares al sistema comercial.



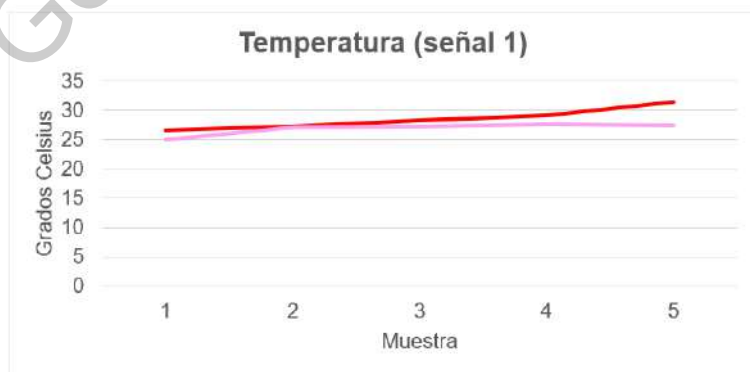
**Figura 4.3.** Gráfico comparativo de saturación de oxígeno en sangre entre el dispositivo desarrollado (gris) y el comercial (azul) de la señal 1 (Autoría propia).

Por otro lado, la Figura 4.4 muestra la gráfica comparativa de las lecturas entre el ritmo cardiaco adquirido mediante el sistema propio y el sistema comercial. La adquisición de los datos comerciales fue realizada de igual modo con el sistema de video. Observando esta figura, es importante mencionar que es posible observar la relación que existe entre el ritmo cardiaco y la oxigenación en sangre, esto debido que a partir de esta se realiza la aproximación del ritmo del corazón, los datos del paciente varían de acuerdo con lo esperado en una señal sana y en estado de relajación ya que la señal varía entre 83 y 60 pulsaciones por minuto.



**Figura 4.4.** Gráfico comparativo de ritmo cardiaco entre el dispositivo propio (naranja) y comercial (amarillo) de la señal 1 (Autoría propia).

Para la validación de los datos de temperatura, en el sistema desarrollado se realiza la toma de manera continua, mientras que, con el sistema comercial, el valor de la temperatura de los participantes se toma en 5 instantes: al inicio, cada minuto y al final del estudio. Es importante aclarar que la toma de la temperatura se hizo sobre el dorso de la mano y sobre la frente, observando que la temperatura entre los 2 puntos variaba aproximadamente 2 grados centígrados, para la validación se tomó en solo en consideración la lectura del dorso de la mano. La Figura 4.5 muestra el valor de la temperatura estimado por el sistema desarrollado (línea de color rojo) y el comercial (línea de color rosa).



**Figura 4.5.** Gráfico comparativo de temperatura entre el dispositivo desarrollado (rojo) y comercial señal 1 (rosa) (Autoría propia).

La Figura 4.6 muestra la gráfica de los valores obtenidos de la respuesta galvánica de la piel con el sistema desarrollado. Los datos obtenidos de esta señal variaron entre 290  $\Omega$  y 315  $\Omega$ . En base a esto, es muy importante mencionar que estos valores se encuentran en el rango establecido para él un paciente relajado que van desde 250  $\Omega$  hasta los 330  $\Omega$  (Seedstudio, 2014). Por lo tanto, el sistema puede estimar correctamente la respuesta galvánica de la piel. En este caso no se hace una comparativa, ya que no se cuenta con el sistema comercial para generar esta.



**Figura 4.6.** Gráfico de valores de GSR de la señal 1 (Autoría propia).

La Tabla 4.1 muestra el error relativo de acuerdo con lo adquirido por el sistema desarrollado y los sistemas comerciales para cada señal/prueba adquirida (oxigenación en sangre, ritmo cardíaco y temperatura), así como el promedio de error que presenta el dispositivo desarrollado para cada una de las señales adquiridas de los 5 pacientes que fueron analizados. De acuerdo con los valores presentados en la tabla se puede mencionar que el sistema desarrollado es capaz de estimar con una buena precisión los valores de oxigenación ya que un error promedio de 1.7% es obtenido. Por otro lado, para el caso del ritmo cardíaco y temperatura se tiene un máximo error del 5.2 y 5.3%, respectivamente, por lo que se requiere posiblemente para mejorar los resultados de un capuchón con la capacidad de adaptarse de mejor manera a las diferentes características de los dedos, también se podría revisar la opción de generar un filtrado adicional a la señal

para eliminar en la medida de lo posible las perturbaciones ambientales, para el caso de la temperatura se puede cambiar el lugar de la toma de muestra para de esta manera evitar el calentamiento que surge a causa del uso del capuchón.

**Tabla 4.1.** Valores de error obtenidos para cada medida adquirida.

No. paciente	Señal	Oxigenación en sangre	Ritmo cardiaco	Temperatura
1	1	0.40 %	3.22%	9.3 %
	2	1.20 %	4.30%	5.8 %
2	3	3.39 %	9.75%	2.3 %
	4	2.02 %	7.03%	3.6 %
3	5	1.48 %	4.09%	5.1%
	6	3.12 %	9.01%	4.9%
4	7	1.15 %	3.88%	6.2%
	8	1.73 %	4.92%	5.6%
5	9	1.42 %	3.09%	4.9%
	10	1.15%	3.54%	5.7%
<b>Error total</b>		1.704%	5.283%	5.34%

## 4.2. Base de datos con señales ECG

### 4.1. Puesta de experimento

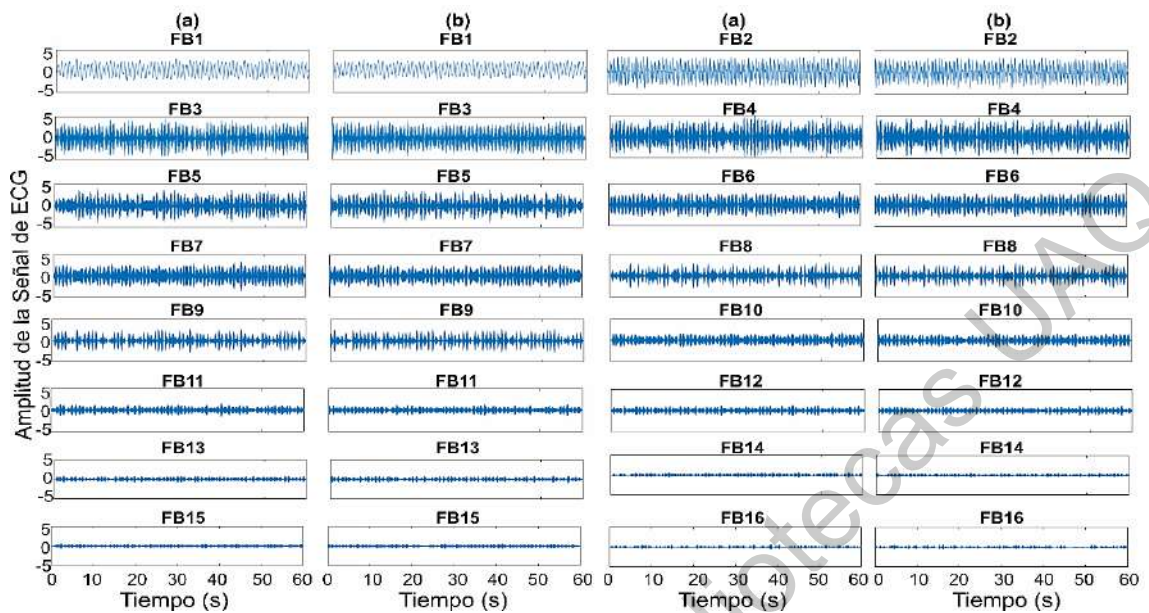
Con la finalidad de validar la metodología propuesta en el presente trabajo de tesis, se analizó la base de datos titulada "Post-Ictal Heart Rate Oscillations in Partial Epilepsy" proporcionada por el Hospital Beth Israel. Esta base de datos contiene 7 señales de ECG, los pacientes tenían edades entre los 31 y 48 años, donde se registraron 10 crisis epilépticas. Es importante aclarar que los pacientes que participaron en este estudio no presentaban evidencia clínica de enfermedades cardíacas y presentaban crisis parciales con o sin generalización secundaria de focos frontales o temporales. La adquisición de los datos se hizo bajo un protocolo aprobado por el Comité de Investigaciones Clínicas del Beth Israel Deaconess Medical Center. (Al-Aweel, *et al.* 1999). Durante el monitoreo de las señales ECG, las personas reclutadas por el Hospital de Boston se encontraban dormidos o descansando en silencio antes de las convulsiones. Con el objeto de precisar el

momento exacto de las convulsiones o crisis epilépticas, se utiliza un sistema de video y señales EEG.

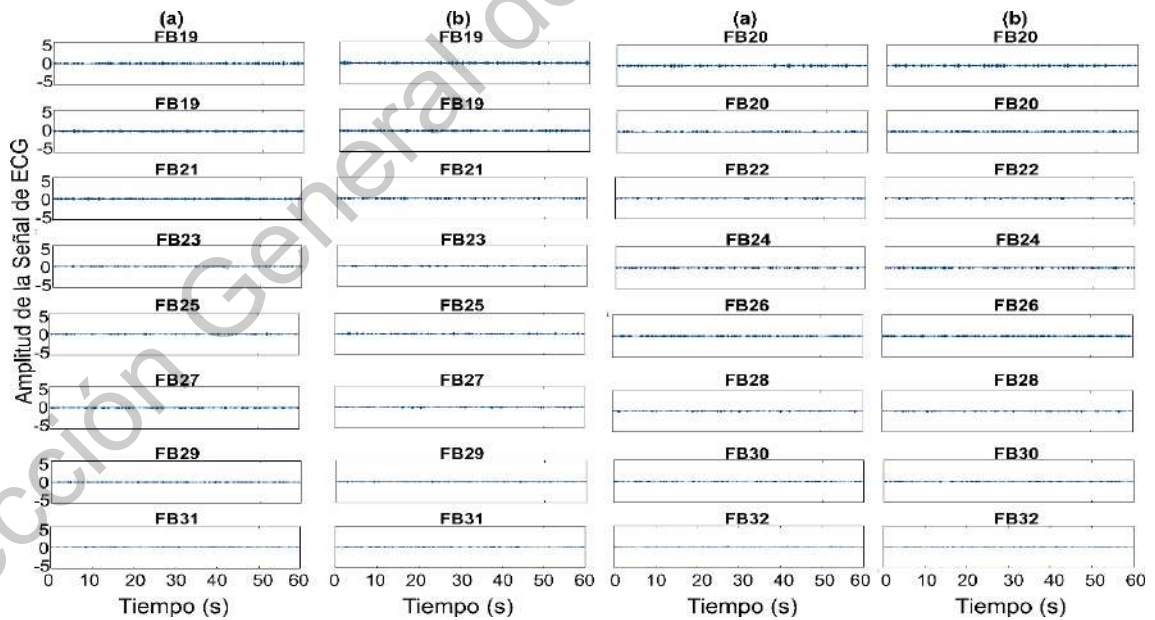
## 4.2. Resultados

Siguiendo los pasos de la metodología propuesta en este trabajo de tesis, las señales ECG monitoreadas, son divididas en intervalos de 1 minuto y analizadas usando la WPT. Es importante señalar que los niveles de descomposición se variaron desde el primer nivel y hasta el octavo nivel, obteniendo como resultado que el quinto nivel de descomposición es el más adecuado para analizar las señales ya que al aumentar el nivel no se presentó una mejora relevante en la precisión, mientras que un nivel de descomposición más bajo resultó en mayor ancho de banda, aumentando las posibilidades de tener una mezcla de frecuencias que podría resultar en una menor precisión del clasificador (Wang *et al.*,2015; Hamzenejad *et al.*,2020). Las Figuras 4.7 a 4.8 muestra las 32 bandas de frecuencia (FB) obtenidas en el nivel 5 para la señal ECG con ritmo cardiaco sano (de acuerdo con las consideraciones expuestas en secciones previas) y de un paciente, 1 minuto antes de la crisis, respectivamente. Observando estas figuras, no existen diferencias visuales entre ambas condiciones. Por lo tanto, se requiere de un método capaz de encontrar características relevantes en estas señales.





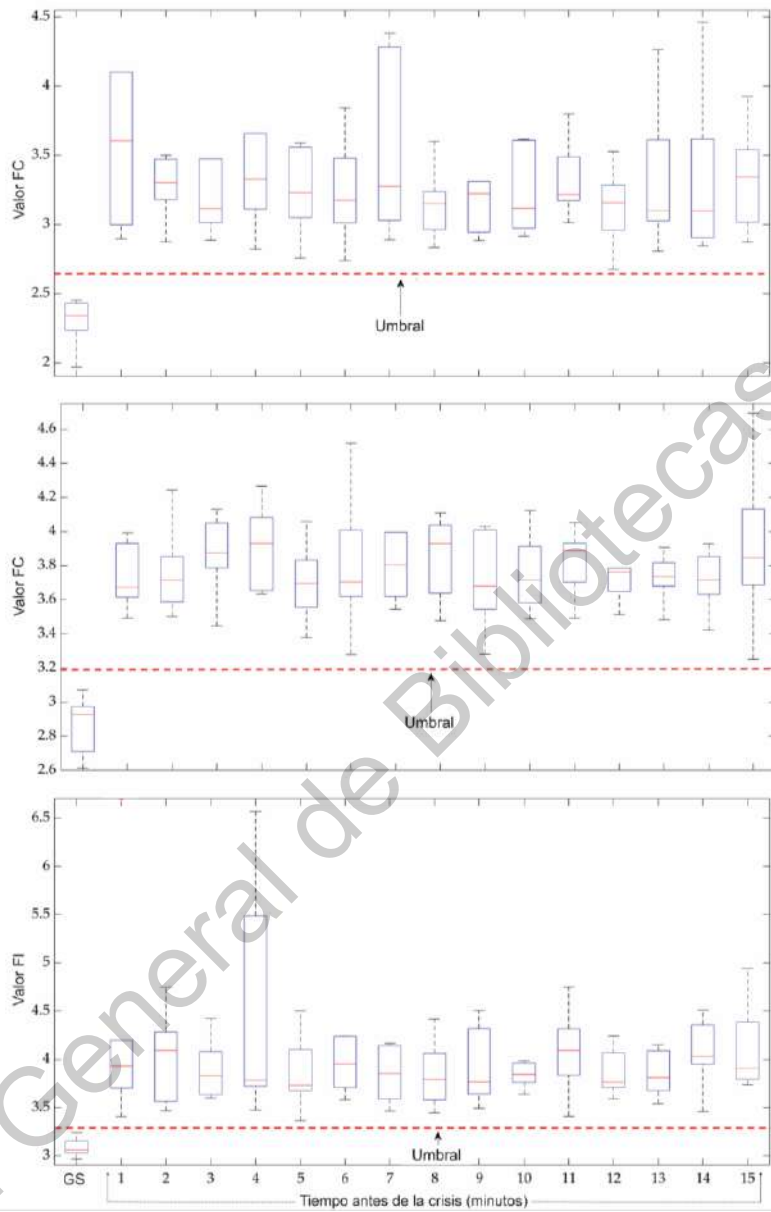
**Figura 4.7.** Descomposiciones estimadas para la WPT (primeras bandas de frecuencia) para la señal ECG de (a) grupo sano y (b) un minuto antes de la crisis (Autoría propia).



**Figura 4.8.** Descomposiciones estimadas para la WPT (últimas bandas de frecuencia) para la señal ECG de (a) grupo sano y (b) un minuto antes de la crisis (Autoría propia).

Una vez descompuestas las señales ECG empleando la WPT, cada uno de los nodos son analizados mediante 5 algoritmos de fractalidad y 17 indicadores estadísticos, para cada uno de los 15 intervalos de tiempo. A continuación, todos los valores estimados mediante los diferentes algoritmos de indicadores no lineales son evaluados por medio del método de Kruskal-Wallis con la finalidad de determinar cuál(es) es la(s) FB(s) e indicador(es) que cuenta con características capaces de predecir oportunamente un evento epiléptico.

Después de un análisis exhaustivo de los valores de fractalidad e indicadores estadísticos empleando el método de Kruskal-Wallis, los resultados obtenidos muestran que el factor cresta (FC) de la banda de frecuencia (FB) 9, el factor impulso (FI) de la banda de frecuencia 12 y el factor cresta de la banda de frecuencia 13 son los más discriminantes ya que presentan los valores de P más bajos, lo que indica que estos indicadores específicamente en estas bandas de frecuencia pueden ser confiables para realizar un diagnóstico anticipado de una crisis epiléptica. La Figura 4.9 muestran la distribución de los valores obtenidos de FC de la FB 9, FI de la FB 12 y el FC de la FB 13 para ambos grupos sano (GS) y con epilepsia. Observando esta figura no se ven superposiciones evidentes entre el grupo GS y la señal del ECG antes de la convulsión desde el primer intervalo de 1 minuto hasta el decimoquinto intervalo de 1 minuto.



**Figura 4.9.** Distribución de los valores de indicadores (eje y) para FC (BF-9), FC (BF-13) y FI (BF-12), para pacientes con ritmo cardíaco normal (GS) y pacientes con crisis epilépticas, en intervalos de 1 minuto hasta 15 minutos (eje x), antes de su ocurrencia (Autoría propia).

La Tabla 4.2 presenta los valores P obtenidos para los indicadores más discriminativos desde el primer intervalo de 1 minuto hasta el decimoquinto intervalo de 1 minuto antes de la crisis epiléptica.

**Tabla 4.2.** Valores de P obtenidos de los indicadores más discriminantes.

Intervalo antes de la crisis	Valor-P		
	FC (FB-9)	FC (FB-13)	Fi (FB-12)
1	2.08x10 <sup>-4</sup>	3.75x10 <sup>-4</sup>	2.08x10 <sup>-4</sup>
2	2.80x10 <sup>-4</sup>	2.08x10 <sup>-4</sup>	2.08x10 <sup>-4</sup>
3	2.08x10 <sup>-4</sup>	6.60x10 <sup>-4</sup>	1.54x10 <sup>-4</sup>
4	1.54x10 <sup>-4</sup>	3.75x10 <sup>-4</sup>	2.08x10 <sup>-4</sup>
5	3.75x10 <sup>-4</sup>	3.75x10 <sup>-4</sup>	2.08x10 <sup>-4</sup>
6	2.08x10 <sup>-4</sup>	6.60x10 <sup>-4</sup>	1.58x10 <sup>-4</sup>
7	2.08x10 <sup>-4</sup>	4.99x10 <sup>-4</sup>	2.08x10 <sup>-4</sup>
8	2.08x10 <sup>-4</sup>	6.60x10 <sup>-4</sup>	2.08x10 <sup>-4</sup>
9	3.75x10 <sup>-4</sup>	4.99x10 <sup>-4</sup>	1.54x10 <sup>-4</sup>
10	2.08x10 <sup>-4</sup>	6.60x10 <sup>-4</sup>	1.58x10 <sup>-4</sup>
11	2.80x10 <sup>-4</sup>	2.80x10 <sup>-4</sup>	2.08x10 <sup>-4</sup>
12	2.80x10 <sup>-4</sup>	6.60x10 <sup>-4</sup>	1.54x10 <sup>-4</sup>
13	2.80x10 <sup>-4</sup>	8.68x10 <sup>-4</sup>	1.58x10 <sup>-4</sup>
14	2.80x10 <sup>-4</sup>	6.60x10 <sup>-4</sup>	2.08x10 <sup>-4</sup>
15	2.80x10 <sup>-4</sup>	4.99x10 <sup>-4</sup>	1.54x10 <sup>-4</sup>

Finalmente, los indicadores seleccionados por medio del método de Kruskal-Wallis, es decir, FC (FB-9), FC (FB-13) y FC (FB-12), son empleados para diseñar un clasificador de árbol de decisión basado en reglas if-else esto con el objetivo de

predecir una convulsión automáticamente. Es importante mencionar que la propuesta es capaz distinguir entre ambos grupos con alta precisión al integrar cualquiera de los indicadores seleccionados con el clasificador ya que sus valores no se sobreponen; sin embargo, a fin de proporcionar más robustez a la metodología de procesamiento de señales propuesta en el caso de evaluar nuevas señales, los tres indicadores seleccionados, son utilizados para desarrollar el clasificador. En este sentido, se determinan tres valores umbral, uno por cada indicador, cada uno de los valores de umbral son seleccionados mediante la realización de una inspección visual, estos son observados en la Figura 4.9 mediante una línea horizontal roja. A partir de esta figura, para los valores de FC (FB-9) > 3.199, FC (FB-13) > 2.684, y FI (FB-12) > 3.267 se consideran como zona de ataque y valores de FC (FB-9) ≤ 3.199, FC (FB-13) ≤ 2.684 y FI (FB-12) ≤ 3.267 se consideran propios de una frecuencia cardíaca normal.

### 4.3. Discusión de resultados

La Tabla 4.3 se presenta una comparación cualitativa entre el presente trabajo y trabajos recientes en esta área del conocimiento, esta se muestra una breve descripción de las metodologías utilizadas, el tiempo de predicción alcanzado, la precisión, especificidad y sensibilidad de acuerdo con lo reportado en los trabajos.

**Tabla 4.3.** Comparación cualitativa del presente trabajo y trabajos recientes en el área de predicción de crisis epilépticas.

Trabajo	Señal	Metodología	Tiempo de predicción
---------	-------	-------------	----------------------

Transformada Wavelet

<b>Asharindavida et al., 2020</b>	EEG	Descomposición empírica de modos Clasificador de aprendizaje profundo	15 minutos (precisión 78.5%)
<b>Giannakakis et al., 2019</b>	HRV	Parámetros espectrales y temporales de la variabilidad de la frecuencia cardiaca Máquina de vectores de soporte	21,8 segundos (77,1% de precisión)
<b>Tsiouris et al., 2018</b>	EEG	Transformada Wavelet Momentos estadísticos Correlación cruzada Redes neuronales convolucionales	15 minutos (precisión 99..28%)
<b>Billeci et al., 2018</b>	RRI	Algoritmo de estado finito y filtro adaptativo para determinar el RRI de la señal 19 indicadores Máquina de vectores de soporte	10 minutos (precisión 74.6)
<b>Popov et al., 2017</b>	HRV	Indicadores (histograma, coeficientes de aproximación polinomial 1° grado, etc.) Máquina de vectores de soporte	20 minutos (sensibilidad y especificidad de 78.52%)
<b>Pavei et al., 2017</b>	HRV	Método de corrección de interpolación de spline cúbico 47 índices no lineales Máquina de vectores de soporte	5 minutos (precisión 95.6 %)
<b>Trabajo presentado</b>	<b>ECG</b>	<b>Transformada Wavelet de paquetes</b> <b>Indicadores estadísticos</b> <b>Análisis estadístico</b> <b>Árbol de decisión</b>	<b>15 minutos (precisión, sensibilidad y especificidad de 100%)</b>

A partir de esta tabla se puede observar que la mayoría de los trabajos previos reportados en la literatura requieren una gran cantidad de características para medir los cambios entre una señales sanas y señales que presentarán una crisis epiléptica. Este hecho puede considerarse como un indicativo de que los índices empleados no captan los sutiles cambios que sufre la señal; en consecuencia, las metodologías utilizadas incrementan su carga computacional, así como la complejidad del algoritmo clasificador, ya que tiene que manejar una cantidad considerable de información. Un hecho interesante que comparten las metodologías recientes es el procesamiento de la señal del ECG para obtener la variabilidad de la frecuencia cardíaca (HRV por sus siglas en inglés Heart Rate Variability). Este hecho incrementa el costo computacional de sus metodologías, limitando la operación de las propuestas en tiempo real. Por el contrario, la propuesta procesa directamente la señal ECG sin procesar, que comprende el costo computacional empleado. Además, de esta tabla también se observa que los indicadores estadísticos son una herramienta adecuada y eficaz para detectar los cambios ECG que el sistema nervioso autónomo puede producir en un evento epiléptico. Además, este trabajo identificó varias bandas de frecuencia (16-18 Hz, 22-24 Hz y 24-26 Hz, respectivamente) que se pueden utilizar para detectar los cambios antes mencionados. Los anchos de banda se encuentran dentro de los valores indicados en la literatura en la cual se indica que la mayor parte de la potencia espectral del ECG se encuentra por debajo de 30 Hz (Willigenburg *et al.*, 2014). Por lo tanto, esto indica que existe una relación entre las crisis epilépticas y la activación del sistema simpático, lo que confirma los hallazgos reportados por Kolsal *et al.* (2014) & Nei *et al.* (2016). En resumen, la propuesta puede considerarse como un método adecuado para predecir pacientes que pueden sufrir una convulsión de forma fiable y precisa.

# Capítulo 5

## 5. Conclusiones y prospectivas

### 5.1. Conclusiones

La epilepsia es conocida como una enfermedad que provoca un desequilibrio en la actividad eléctrica de las neuronas del cerebro, generando convulsiones en los pacientes. Dado que la convulsión puede generar escenarios potencialmente mortales, un diagnóstico anticipado de eventos epilépticos permitirá a los pacientes colocarse en un lugar seguro, evitando sufrir caídas, ahogamientos y quemaduras, así como recibir el tratamiento médico adecuado. En este trabajo de tesis, se propone una metodología basada en la unión de la transformada Wavelet, indicadores no lineales (5 tipos de dimensión fractal y 18 indicadores estadísticos) y un clasificador basado en un árbol de decisiones, para predecir una convulsión de forma automática mediante el empleo de señales de ECG. Los resultados muestran una precisión del 100%, una sensibilidad del 100% y una especificidad del 100% en una ventana de 15 minutos antes de la convulsión utilizando los 150 segmentos de señal de convulsión, 15 intervalos de 1 minuto para las 10 condiciones epilépticas sufridas por 7 pacientes y 10 segmentos de señal tomada como sana, superando los trabajos previos reportados en la literatura. Los resultados obtenidos son mejores que trabajos previos en cuanto a carga computacional (procesamiento de ECG sin conversiones) y exactitud (4.6% más exacto). El presente trabajo cuenta con una precisión de predicción de 100 % para anticipar una crisis 15 minutos antes de su manifestación. Por otro lado, se desarrolló un sistema de adquisición portátil capaz de monitorear diversos biopotenciales (ritmo cardiaco, oxigenación en sangre, respuesta galvánica de la piel y temperatura) pues se emplea una micro SD para el almacenamiento de los datos, lo cual permite su posterior uso. El sistema de adquisición desarrollado tiene una eficiencia del 94.36% en comparación con los sistemas comerciales.



A partir de los resultados obtenidos en el presente trabajo, la hipótesis planteada fue cumplida, ya que se demostró que la metodología propuesta para el procesamiento de los datos tiene la capacidad de predecir una crisis epiléptica con el uso de algoritmos de baja carga computacional. A partir de la presente investigación se obtuvieron 2 productos (artículo de congreso y un artículo JCR), en las cuales se analizó la eficiencia de diferentes indicadores no lineales y en base a estos se eligió el clasificador que resultaba más conveniente de acuerdo con la capacidad de cada indicador para diferenciar entre una señal sana y una sufriría una crisis epiléptica.

## 5.2. Prospectivas

Partiendo de los resultados obtenidos y las conclusiones expuestas en el apartado anterior, a continuación, se plantean las prospectivas para futuros trabajos y avances sobre el tema.

- Probar la propuesta utilizando una base de datos más grande para corroborar que la activación del sistema simpático cuando el paciente es propenso a sufrir una convulsión puede permitir detectar la convulsión como lo señala (Lotufo *et al.*,2012); en este sentido, se puede asegurar la viabilidad de la propuesta, permitiendo modificar o calibrar según nuevos resultados.
- Seleccionar una ventana de tiempo de predicción mayor (por ejemplo, 40 minutos antes del inicio de la convulsión), ya que esta ventana de tiempo puede permitir el paciente para encontrar un lugar seguro donde los movimientos asociados a la convulsión no comprometan un riesgo para la integridad del paciente y su entorno; además, permitirá que el paciente llegue a un hospital para que se puedan llevar a cabo las acciones correctivas adecuadas, asegurando una recuperación más rápida.

- Mejorar el sistema adquisición para aumentar el porcentaje de precisión del sistema en comparación con los sistemas comerciales, en este sentido se propone el mejoramiento de la carcasa que recubre el sensor.

Dirección General de Bibliotecas UAQ

## Referencias

- Abdullah, S. (2005). Wavelet bump extraction (WBE) for editing variable amplitude fatigue loadings. University of Sheffield, United Kingdom (Thesis Doctoral).
- Acharya, U. R., Hagiwara, Y., & Adeli, H. (2018). Automated seizure prediction. *Epilepsy & Behavior*, 88, 251-261.
- Adeli, H., Zhou, Z., & Dadmehr, N. (2003). Analysis of EEG records in an epileptic patient using wavelet transform. *Journal of neuroscience methods*, 123(1), 69-87.
- Ahmadlou, M., Adeli, H., & Adeli, A. (2011). Fractality and a wavelet-chaos-methodology for EEG-based diagnosis of Alzheimer disease. *Alzheimer Disease & Associated Disorders*, 25(1), 85-92.
- Aileni, M. R., Bogdan, H., & Sever, P. (2018, June). Wavelet transform for seizure detection in EEG records. In *IEEE 2018 10th International Conference on Electronics, Computers and Artificial Intelligence*, pp. 1-6.
- Allen J. (2007). Photoplethysmography and its applications in clinical physiological measurement, *Physiol. Meas.* 28, R1-R3.
- Amezquita-Sanchez, J. P., *et al.* (2017). Fractal dimension and fuzzy logic systems for broken rotor bar detection in induction motors at start-up and steady-state regimes. *Measurement Science and Technology*, 28(7), 075001.
- Amezquita-Sanchez, J. P., & Adeli, H. (2015). Synchrosqueezed wavelet transform-fractality model for locating, detecting, and quantifying damage in smart highrise building structures. *Smart Materials and Structures*, 24(6), 065034.
- Amezquita-Sanchez, J. P., & Adeli, H. (2019). Nonlinear measurements for feature extraction in structural health monitoring. *Scientia Iranica. Transaction A, Civil Engineering*, 26(6), 3051-3059.

Amezquita-Sanchez, J. P., Valtierra-Rodriguez, M., Camarena-Martinez, D., Granados-Lieberman, D., Romero-Troncoso, R. J., & Dominguez-Gonzalez, A. (2016). Fractal dimension-based approach for detection of multiple combined faults on induction motors. *Journal of Vibration and Control*, 22(17), 3638-3648.

Amezquita-Sanchez, J. P., & Adeli, H. (2015). A new music-empirical wavelet transform methodology for time–frequency analysis of noisy nonlinear and non-stationary signals. *Digital Signal Processing*, 45, 55-68.

Asharindavida, F., *et al.* (2020). A forecasting tool for prediction of epileptic seizures using a machine learning approach. *Concurrency and Computation: Practice and Experience*, 32(1), e5111.

Babajanian Bisheh, H., Ghodrati Amiri, G., Nekooei, M., & Darvishan, E. (2019). Damage detection of a cable-stayed bridge using feature extraction and selection methods. *Structure and Infrastructure Engineering*, 15(9), 1165-1177.

Billeci, L.; Marino, D.; Insana, L., Vatti, G.; Varanini, M. (2018) Patient-specific seizure prediction based on heart rate variability and recurrence quantification analysis. *PLoS One.*, 13, 1–21.

Boucsein, W. (2012). *Electrodermal activity*. Springer Science & Business Media.

Caesarendra, W., Tjahjowidodo, T. (2017). A Review of feature extraction methods in vibration-based condition monitoring and its application for degradation trend estimation of low-speed slew bearing. *Machines*. 5, 21.

Carrasco Gonzaga A. (2019). Desarrolló de un sistema de adquisición y procesamiento basado en la transformada de Fourier y LabView para señales eléctricas cardiacas. [Tesis de Licenciatura]. Universidad Autónoma de Querétaro.

Cavazos Juárez A. (2018). Clasificador de señales cerebrales. (Tesis de Posgrado). Benemérita Universidad Autónoma de Puebla.

Choudhury, N. R., Roy, S. S., Pal, A., Chatterjee, S., & Bose, R. (2018, November). Epileptic Seizure Detection Employing Cross-Hyperbolic Stockwell Transform. In IEEE 2018 Fourth International Conference on Research in Computational Intelligence and Communication Networks, pp. 70-74.

Chávez Elías A. F. (2018). Síntesis y actividad antiepiléptica de pirrolidonas 1,4-disustituidas". (Tesis de Posgrado). Universidad Autónoma de Querétaro.

CIOMS & OMS. (2016). Pautas éticas internacionales para la investigación biomédica en seres human. Ginebra. OMS.

Cortés, J. A., Garzón, H. B. C., & Chaves, J. A. (2007). Del análisis de Fourier a las Wavelets-transformada continua wavelet (CWT). Scientia et technica, 1(37).

Cruz Ramírez H. (2018). Metodología basada en la descomposición empírica de modos completa y fractales para la clasificación de la imaginación motora usando señales electroencefalográficas. (Tesis de Licenciatura). Universidad Autónoma de Querétaro.

Cuesta D. (1999). Revisión de Métodos y Algoritmos para el Tratamiento de Señales Electrocardiográficas. Trabajo de Investigación.

De Aguirre M. I. (2012). Epilepsia y corazón. Cardiología e hipertensión. Noticias del instituto de investigaciones cardiológicas. Prof. Dr. Alberto C. Taquini, número especial dedicado a corazón y epilepsia, pp. 5-11

Delgado-Prieto, M., Cirrincione, G., Espinosa, A. G., Ortega, J. A., & Henao, H. (2012). Bearing fault detection by a novel condition-monitoring scheme based on statistical-time features and neural networks. IEEE Transactions on Industrial Electronics, 60(8), 3398-3407.

Deperlioglu, O. & Kose, U. (2011). An educational tool for artificial neural networks. Computers & Electrical Engineering. 37, 392-402.

Devore, J.L. & Berk, K.N. (2013). Overview and descriptive statistics. *Modern Mathematical Statistics with Applications*. Springer, New York, NY. 1-49.

Edelberg, R. (1967). Electrical properties of the skin. *Methods in psychophysiology* Baltimore: Williams & Wilkins, 1-57.

Elhaj, F. A., Salim, N., Harris, A. R., Swee, T. T., & Ahmed, T. (2016). Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals. *Computer methods and programs in biomedicine*, 127, 52-63.

England M. J., Liverman C. T., Schultz A. M., & Strawbridge I. M. (2012). "Quality of life and community resources". National Institutes of Health.

Epilepsy society. (2016). "What is epilepsy? An introduction" <https://www.epilepsysociety.org.uk/sites/default/files/attachments/whatisepilepsydec2016.pdf>

Freeman, W. J. (2004a). Origin, structure, and role of background EEG activity. Part 1. Analytic amplitude. *Clinical Neurophysiology*, 115(9), 2077–2088.

Freeman, W. J. (2004b). Origin, structure, and role of background EEG activity. Part 2. Analytic phase. *Clinical Neurophysiology*, 115(9), 2089–2107.

Friesen, G. M., Jannett, T. C., Jadallah, M. A., Yates, S. L., Quint, S. R., & Nagle, H. T. (1990). A comparison of the noise sensitivity of nine QRS detection algorithms. *IEEE Transactions on biomedical engineering*, 37(1), 85-98.

García, T. (2015). Acquiring the 12-lead electrocardiogram: doing it right every time. *Journal of Emergency Nursing*, 41(6), 474-478.

García-Zamora. S., Malpica-Cervantes, F., De Valais, F., Gonzales-Zuelgaray, J. (2012). Epilepsia y arritmias cardíacas. *Cardiología e hipertensión*. Noticias del instituto de investigaciones cardiológicas. Prof. Dr. Alberto C. Taquini. Número especial dedicado a corazón y epilepsia, pp. 12-18.

Ghorbani Afkhami, R., Azarnia, G., Tinati, M.A. (2016). Cardiac arrhythmia classification using statistical and mixture modeling features of ECG signals. *Pattern Recognit. Lett.* 70, 45–51.

Giannakakis, G., Tsiknakis, M., & Vorgia, P. (2019). Focal epileptic seizures anticipation based on patterns of heart rate variability parameters. *Computer methods and programs in biomedicine*, 178, 123-133.

Hassan, A.R., Bhuiyan, M.I. (2016). Automatic sleep scoring using statistical features in the EMD domain and ensemble methods. *Biocybern. Biomed. Eng.* 36, 248–255.

He Victor. (2015). *Grove–GSR. Seed Grow the difference*, pp. 1-7.

Hernandez-Vargas, M., Cabal-Yepez, E., & Garcia-Perez, A. (2014). Real-time SVD-based detection of multiple combined faults in induction motors. *Computers & Electrical Engineering*, 40(7), 2193-2203.

Higuchi, T. (1988). Approach to an irregular time series on the basis of the fractal theory. *Physica D: Nonlinear Phenomena*, 31(2), 277-283.

Ieracitano, C., *et al.* (2019). A Time-Frequency based Machine Learning System for Brain States Classification via EEG Signal Processing. In *IEEE 2019 International Joint Conference on Neural Networks*, pp. 1-8.

Igba, J., Alemzadeh, K., Durugbo, C., & Eiriksson, E. T. (2016). Analysing RMS and peak values of vibration signals for condition monitoring of wind turbine gearboxes. *Renewable Energy*, 91, 90-106.

Jana, R., Bhattacharyya, S., & Das, S. (2020). Patient-Specific Seizure Prediction Using the Convolutional Neural Networks. In *Intelligence Enabled Research*, Springer, Singapore, pp. 51-60.

Jasper, H. H. (1958). "The ten-twenty electrode system of the international federation electroencephalogram". *Clinical Neurophysiology*, 10, 367–380.

Jiménez Arthur, A. M. (2015). Sistema de visión artificial basado en termografía para segmentación automática y detección de puntos críticos en la planta del pie. (Tesis de Maestría). Universidad Autónoma de Querétaro.

Johnson, L. C., & Lubin, A. (1966). Spontaneous electrodermal activity during waking and sleeping. *Psychophysiology*, 3, 8–17.

Jukić, S., Kečo, D., & Kevrić, J. (2018). Majority Vote of Ensemble Machine Learning Methods for Real-Time Epilepsy Prediction Applied on EEG Pediatric Data. *TEM Journal*, 7(2), 313.

Katz, M. (1988). Fractals and the analysis of waveforms. *Computers in Biology and Medicine*, 18, 145-156.

Kolsal, E., *et al.* (2014). Can heart rate variability in children with epilepsy be used to predict seizures?. *Seizure*, 23(5), 357-362.

Leis J. W. (2011). Digital signal processing using MATLAB for students and researchers. John Wiley & Sons, Inc.

Ley Federal de Protección de Datos Personales En Posesión de los Particulares. Diario Oficial de la Federación, México, 5 de Julio de 2010.

Lopez-Ramirez, *et al.* (2016). EMD-Based Feature Extraction for Power Quality Disturbance Classification Using Moments. *Energies*, 9, 565.

Matsuo, T., Inuma, K., & Esashi, M. (1973). A barium-titanate-ceramics capacitive-type EEG electrode. *IEEE Transactions on Biomedical Engineering*, (4), 299-300.

Maxim integrated. (2016). "MAX30105". Recupera el 28 de Marzo de 2020, de Maxim integrated Sitio web: [https://cdn.sparkfun.com/assets/learn\\_tutorials/5/7/7/MAX30105\\_3.pdf](https://cdn.sparkfun.com/assets/learn_tutorials/5/7/7/MAX30105_3.pdf)

Moreno-Gomez, A., *et al.* (2018). EMD-Shannon entropy-based methodology to detect incipient damages in a truss structure. *Applied Sciences*, 8(11), 2068.



Nei, M., *et al.* (2016). Heart rate and blood pressure in sudden unexpected death in epilepsy (SUDEP). *Epilepsy research*, 122, 44-46.

Neuman M.R. (2009). Biopotential electrodes. JW Webster (ed.), *Medical instrumentation: application and design*. John Wiley and sons, 4th ed. 189-209.

Oliveros-Oliveros J. J., Morín-Castillo M. M., Aquino Camacho F. A., & Fraguela-Collar A. (2015). Análisis Del Problema Directo Electroencefalográfico Para Fuentes Dipolares Corticales". *Décima Cuarta Conferencia Iberoamericana en Sistemas, Cibernética e Informática CISCI, Décimo Segundo Simposium Iberoamericano en Educación, Cibernética e Informática, SIECI Memorias*, pp. 52–56.

Pakyari, R. & Balakrishnan, N. (2012). A general-purpose approximate goodness-of-fit test for progressively Type-II censored data. *IEEE Transactions on Reliability*, 61, 238-244.

Palaniswamy, U.R. & Palaniswamy, K.M. (2005) *Teaching and Research in Plant and Crop Science*. New York: Food Products and The Haworth Reference Press.

Parker B.(2003). Reusable pulse oximeter probe and disposable bandage apparatus. United States patent. No. 6,519,487 B1

Paul, J. K., *et al.* (2019). Characterization of fibromyalgia using sleep EEG signals with nonlinear dynamical features. *Computers in biology and medicine*, 111, 103331.

Pavei, J.; Heinzen, R.G.; Novakova, B.; Walz, R.; Serra, A.J.; Reuber, M.; Marques, J.L. (2018) Early seizure detection based on cardiac autonomic regulation dynamics. *Front. Physiol*, 8, 1–12.

Petrosian, A. (1995). Kolmogorov Complexity of Finite Sequences and Recognition of Different Preictal EEG Patterns. In *Proceedings of the Computer-Based Medical Systems*, Lubbock, TX, USA, pp. 212–221.

Piña Vega R. (2019). Metodología basada en dimensión fractal y lógica difusa para la predicción de infartos empleando señales ECG. (Tesis de Licenciatura). Universidad Autónoma de Querétaro.

Popov, A., *et al.* (2017). Heart beat-to-beat intervals classification for epileptic seizure prediction. In IEEE 2017 Signal Processing Symposium, pp. 1-4).

Pérez Sánchez A. V. (2018). Metodología basada en la transformada wavelet y fractales para la detección anticipada de eventos epilépticos. (Tesis de Licenciatura). Universidad Autónoma de Querétaro.

Ramgopal, S., *et al.* (2014). Seizure detection, seizure prediction, and closed-loop warning systems in epilepsy. *Epilepsy & behavior*, 37, 291-307.

Ramírez Díaz Gabriela. (2013). Calidad de vida en pacientes adultos con epilepsia. (Tesis de Posgrado). Universidad Autónoma de Querétaro.

Reda, T.M. Noureldin, A., Lucero, J. L., & Baca, T. J. (2006). Wavelet transform for structural health monitoring: a compendium of uses and features. *Structural health monitoring*, 5(3), 267-295.

Rojas-Pérez Eduardo M. (2006) Factores que afectan la oximetría de pulso. *Revista Mexicana de Anestesiología*, 29, 8193-8198.

Ruiz Vázquez C. (2019). Metodología basada en la transformada wavelet y los parámetros de Hjorth para la clasificación de imaginación motora usando señales electroencefalográficas. (Tesis de Licenciatura). Universidad Autónoma de Querétaro.

Saucedo-Dorantes, J. J., Delgado-Prieto, M., Romero-Troncoso, R. D. J., & Osornio-Rios, R. A. (2019). Multiple-fault detection and identification scheme based on hierarchical self-organizing maps applied to an electric machine. *Applied Soft Computing*, 81, 105497.

Scheffé Henry. (1999). *The Analysis of Variance*. John Wiley & Sons.

Sevcik, C.(1998). A Procedure to Estimate the Fractal Dimension of Waveforms. *Complex*, 5, 1–19.

Sheng Y. (1996) *The Transforms and Applications Handbook*. CRC Press.

Sica R. E. (2012). “Epilepsia y corazón: una asociación particular”. *Cardiología e hipertensión*. Noticias del instituto de investigaciones cardiológicas Prof. Dr. Alberto C. Taquini, número especial dedicado a corazón y epilepsia, pp. 2-4

Siuly, S., Li, Y., & Zhang, Y. (2016). EEG signal analysis and classification. *IEEE Trans Neural Syst Rehabil Eng*, 11, 141-4. Taylor J, Jacoby A, Baker G.A,

Marson A.G. (2011). Self-reported and parent-reported quality of life of children and adolescents with new-onset epilepsy. *Epilepsia*, 52(8), 1489–1498.

Treo E., *et al.* (2009). Efecto del gel y limpieza en la impedancia electrodo-piel en registros de superficie. Congreso argentino de bio-ingeniería, pp. 21-22.

Tsiouris, K. M., *et al.* (2018). A Long Short-Term Memory deep learning network for the prediction of epileptic seizures using EEG signals. *Computers in biology and medicine*, 99, 24-37.

Vargas López O. (2019). Metodología basada en la EMD y medidas no lineales prevalentes en muerte súbita cardíaca. (Tesis de Licenciatura). Universidad Autónoma de Querétaro.

Vaurio L., Karantzoulis S., & Barr W.B. (2017). The Impact of Epilepsy on Quality of Life. Chiaravalloti N., Goverover Y. (eds) *Changes in the Brain*. Springer, New York, NY

Vega Mancilla, S. Y. (2016). Procesamiento de imágenes termográficas en la detección de cáncer de mama. (Tesis de Posgrado). Universidad Autónoma de Querétaro.

Venables, P. H., & Christie, M. J. (1980). Electrodermal activity. In I. Martin & P. H. Venables (Eds.), *Techniques in psychophysiology*. New York: Wiley, 3–67.

Vera O. *et al.* (2006). Extracción de características de la señal electrocardiográfica mediante software de análisis matemático. *Scientia et Technical*, 31, 59-67.

Vignolo, B. J. (2008). Introducción al procesamiento digital de señales. Chile. Ediciones Universitarias de Valparaíso, pp. 19-20.

Vázquez Rodríguez, P. (2013). "Evaluación termográfica del pie diabético y su asociación con la retinopatía diabética". (Tesis de Posgrado). Universidad Autónoma de Querétaro.

Wang, B. (2005). Detection of structural damage using fractal. *Journal of Vibration and Shock*, 24, 87-88.

Yanez-Borjas, J.J., Valtierra-Rodriguez, M., Camarena-Martinez, D., Amezcua-Sanchez, J.P. (2020). Statistical time features for global corrosion assessment in a truss bridge from vibration signals. *Meas. J. Int. Meas. Confed.* 160, 107858.

# Anexos

## Anexo 1. Carta de consentimiento informado

### CONSENTIMIENTO INFORMADO

Lugar y fecha: \_\_\_\_\_.

Por medio del presente acepto que mi hijo participe en el protocolo de investigación titulado: **“Detección anticipada de eventos epilépticos, empleando características no lineales”**. cuyo objetivo es: Determinar y encontrar indicadores propios de un evento epiléptico mediante el estudio de señales de resistencia galvánica de la piel, saturación de oxígeno en sangre y ritmo cardiaco.

Se me ha explicado que mi participación consistirá en: la medición de señales de resistencia galvánica de la piel, saturación de oxígeno en sangre y ritmo cardiaco, se colocarán 2 electrodos en los dedos índice y medio, un sensor de pulso en el dedo anular. Posteriormente se llevará a cabo el muestreo de la señal. Entiendo que se conserva el derecho de retirarse del estudio en cualquier momento que lo considere conveniente. También se han comprometido a proporcionarme la información actualizada que se obtenga durante el estudio, aunque esta pudiera cambiar de parecer respecto a la permanencia en el mismo.

El número telefónico al cual puedo comunicarme en caso de emergencia, dudas o preguntas relacionadas con el estudio: \_\_\_\_\_

El Investigador Responsable se ha comprometido a darme información oportuna sobre cualquier procedimiento alternativo, así como a responder cualquier pregunta y aclarar cualquier duda que le plantee.

---

Nombre y firma del tutor del paciente

## Anexo 2. Carta de confidencialidad

### Carta confidencialidad

Lugar y fecha: \_\_\_\_\_

Por medio de la presente yo, **Andrea Viviana Pérez Sánchez**, en calidad de investigador del proyecto titulado “**Detección anticipada de eventos epilépticos, empleando características no lineales**”, entiendo que toda aquella información brindada por el paciente es de carácter confidencial y queda prohibido cualquier tipo de revelación o divulgamiento por cualquiera de las partes por medios escritos, orales o de cualquier otra forma.

Me comprometo a restringir el acceso a la información confidencial solo a aquellas personas vinculadas al proyecto de investigación en calidad de investigadores o auxiliares de investigación que tengan necesidad de conocerla para el desarrollo del mismo y por tanto mantener la más estricta confidencialidad y no revelar a otras personas físicas o morales cualquier información confidencial con otros fines distintos a los del proyecto.

De la misma manera confirmo que los datos personales y cualquier identificación del paciente serán manejados de forma confidencial en las presentaciones o publicaciones que deriven de este estudio.

\_\_\_\_\_  
Investigador responsable

**Anexo 3. Artículo Presentado en el Coloquio 14 de Posgrado de Ingeniería 2020**



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO



FACULTAD DE INGENIERÍA



DIPFI POSGRADO INGENIERÍA



CONACYT



Se otorga la presente

**CONSTANCIA**

a:

**ANDREA VIVIANA PÉREZ-SÁNCHEZ**

Por su participación en el Coloquio 14° del Posgrado de Ingeniería

**METODOLOGÍA BASADA EN TRANSFORMADA WAVELET Y DIMENSIÓN FRACTAL PARA LA PREDICCIÓN DE CRISIS EPILÉPTICAS MEDIANTE SEÑALES DE ECG**

Universidad Autónoma de Querétaro  
Facultad de Ingeniería C.U.  
Noviembre 2020



Dr. Manuel Toledano Ayala  
DIRECTOR  
FACULTAD DE INGENIERÍA

## “Methodology based on Wavelet Transform and Fractal Dimension for epileptic seizures prediction using ECG signals”

“Metodología basada en Transformada Wavelet y Dimensión Fractal para la predicción de crisis epilépticas mediante señales de ECG”

Andrea V. Perez-Sanchez<sup>1\*</sup>, Martin Valtierra-Rodriguez<sup>1</sup>, and Juan P. Amezcua-Sanchez<sup>1,\*</sup>

<sup>1</sup> Facultad de Ingeniería, Universidad Autónoma de Querétaro (UAQ), Campus San Juan del Río, Río Moctezuma 249, Col. San Cayetano, San Juan del Río, Qro. C. P. 76807, México.

\* Correspondence: aperez07@alumnos.uaq.mx, jamezcua@uaq.mx

### Abstract

Epilepsy is characterized by being a neurological condition that tends to produce seizures, which can affect the thought, movement, and feelings of a patient. In this regard, this affection puts in a permanent risk of death to the patients because of falls, drowning, burns, and prolonged seizures that they can suffer. Hence, it is of vital importance to propose a method or methodology with the capability of predicting a seizure with several minutes before the onset, allowing that the patients locate a safe place or take their precautions against injuries as well as receive timely medical treatment. In this regard, a new methodology for predicting epileptic seizures using electrocardiogram (ECG) signals is presented in this work. It is based on the integration of diverse signals processing techniques: wavelet packet transform, fractal dimension, and multi-layer perceptron artificial neural networks. Three fractal dimension algorithms methods to discover patterns or features into the ECG signals are investigated in this work: Katz, Higuchi, and Box Dimension. The effectiveness of the proposed methodology for predicting an epileptic event is demonstrated using a database of 7 patients with 10 epileptic seizures and 18 normal, provided by Massachusetts Institute of Technology-Beth Israel Hospital (MIT-BIH). The results show that the proposed methodology is capable of predicting 5 minutes before an epileptic seizure with an accuracy of 97.5%.

**Keywords:** MEC (Mechatronic), Seizure Prediction; Electrocardiogram (ECG) signals; Wavelet Packet Transform; Fractal Dimension; Artificial neural networks.

### Resumen

La epilepsia se caracteriza por ser una afección neurológica que tiende a producir convulsiones, las cuales pueden afectar el pensamiento, el movimiento y el sentimiento de un paciente. En este sentido, esta afección pone en riesgo permanente de muerte a los pacientes debido a posibles caídas, ahogamientos, quemaduras y convulsiones prolongadas que puedan sufrir durante la crisis. Por estas razones, es de vital importancia proponer un método o metodología con capacidad de predecir una convulsión minutos antes de su inicio, permitiéndole a los pacientes que busquen un lugar seguro o tomen sus precauciones ante lesiones, así como también recibir tratamiento médico oportuno. En este sentido, este trabajo presenta una nueva metodología para predecir crisis epilépticas mediante señales de electrocardiograma (ECG). Esta propuesta se basa en la integración de diversas técnicas de procesamiento de señales: la transformada wavelet (ondas) de paquetes, dimensión fractal y redes neuronales artificiales de perceptrón multicapa. En este trabajo se investigan tres métodos de algoritmos de dimensión fractal para descubrir patrones o características en las señales de ECG: Katz, Higuchi y Dimensión de Caja. La efectividad de la metodología propuesta para predecir un evento epiléptico se demuestra utilizando una base de datos de 7 pacientes con 10 crisis epilépticas y 18 normales, proporcionada por el Instituto de Tecnología de Massachusetts - Hospital Beth Israel (MIT-BIH por sus siglas en inglés *Massachusetts Institute of Technology - Beth Israel Hospital*). Los resultados muestran que la metodología propuesta es capaz de predecir 5 minutos antes de un ataque epiléptico con una precisión del 97.5%.

**Palabras Clave:** MEC (Mecatrónica), Predicción de convulsiones, Electrocardiograma (ECG), Transformada Wavelet de Paquetes, Dimensión Fractal, Redes Neuronales



## Anexo 4. Artículo Publicado en Mathematics 2020



Article

# Wavelet Transform-Statistical Time Features-Based Methodology for Epileptic Seizure Prediction Using Electrocardiogram Signals

Andrea V. Perez-Sanchez <sup>1</sup>, Carlos A. Perez-Ramirez <sup>2</sup>, Martin Valtierra-Rodriguez <sup>1</sup>, Aurelio Dominguez-Gonzalez <sup>1</sup> and Juan P. Amezcua-Sanchez <sup>1,\*</sup>

<sup>1</sup> ENAP-Research Group, CA-Sistemas Dinámicos, Facultad de Ingeniería, Universidad Autónoma de Querétaro (UAQ), Campus San Juan del Río, Río Moctezuma 249, Col. San Cayetano, San Juan del Río 76807, Mexico; aperez07@alumnos.uaq.mx (A.V.P.-S.); martin.valtierra@enap-rg.org (M.V.-R.); auredgz@uaq.mx (A.D.-G.)

<sup>2</sup> ENAP-Research Group, Facultad de Ingeniería, Universidad Autónoma de Querétaro (UAQ), Campus Aeropuerto, Carretera a Chichimequillas S/N, Ejido Bolaños, Santiago de Querétaro 76140, Mexico; carlos.perez@uaq.mx

\* Correspondence: juan.amezcua@enap-rg.org

Received: 30 October 2020; Accepted: 25 November 2020; Published: 27 November 2020



**Abstract:** Epilepsy is a brain disorder that affects about 50 million persons around the world and is characterized by generating recurrent seizures, which can put patients in permanent because of falls, drowning, burns, and prolonged seizures that they can suffer. Hence, it is of vital importance to propose a methodology with the capability of predicting a seizure with several minutes before the onset, allowing that the patients take their precautions against injuries. In this regard, a methodology based on the wavelet packet transform (WPT), statistical time features (STFs), and a decision tree classifier (DTC) for predicting an epileptic seizure using electrocardiogram (ECG) signals is presented. Seventeen STFs were analyzed to measure changes in the properties of ECG signals and find characteristics capable of differentiating between healthy and 15 min prior to seizure signals. The effectiveness of the proposed methodology for predicting an epileptic event is demonstrated using a database of seven patients with 10 epileptic seizures, which was provided by the Massachusetts Institute of Technology–Beth Israel Hospital (MIT–BIH). The results show that the proposed methodology is capable of predicting an epileptic seizure 15 min before with an accuracy of 100%. Our results suggest that the use of STFs at frequency bands related to heart activity to find parameters for the prediction of epileptic seizures is suitable.

**Keywords:** seizure prediction; ECG signals; wavelet transform; statistical time features

### 1. Introduction

Epilepsy is a brain disorder that affects about 50 million persons around the world and is characterized by generating recurrent seizures [1]. In particular, the brain contains billions of nerve cells or neurons that help people to control their way of (1) thinking, (2) moving, and (3) feeling by means of electrical signals that send messages from one nerve cell to others [2]. In this regard, the brain is characterized by allowing the neurons to send electrical signals at a rate that is under 100 times per second, but during an epileptic seizure or ictal state, the neurons become hyperexcitable, which causes a period of abnormal and asynchronous excitation in a neuronal population, generating muscular contractions that are uncontrollable [3,4]. This reaction can lead to the patients suffering physical problems (i.e., fractures and bruising related to seizures) and psychological conditions (i.e., anxiety and depression), negatively affecting their life quality [5,6]. In addition, they present a permanent