

Universidad Autónoma de Querétaro

Facultad de Ingeniería

Ingeniería Biomédica



“Metodología basada en la EMD y medidas no lineales prevalentes en Muerte Súbita Cardíaca”

TESIS

Que como parte de los requisitos para obtener el título de Ingeniero Biomédico
línea terminal Bioseñales y Bioinstrumentación

Presenta

Olivia Vargas López

Dirigida por

Dr. Carlos Andrés Pérez Ramírez

Dr. Juan Pablo Amézquita Sánchez

Santiago de Querétaro, Qro., Mayo del 2019.



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Ingeniería Biomédica



“Metodología basada en la EMD y medidas no lineales prevalentes en Muerte Súbita Cardíaca”

Tesis

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

Presenta:

Olivia Vargas López

Dirigido por:

Dr. Carlos Andrés Pérez Ramírez
Dr. Juan Pablo Amézquita Sánchez

Dr. Carlos Andrés Pérez Ramírez
Presidente

Firma

Dr. Juan Pablo Amézquita Sánchez
Secretario

Firma

Dr. Martín Valtierra Rodríguez
Vocal

Firma

M. C. Eduardo Martínez Segoviano
Suplente

Firma

Centro Universitario
Querétaro, Qro.
Mayo, 2019

RESUMEN

Las muertes en personas ocasionadas por afecciones cardíacas están en crecimiento con el paso de los años. En muchas ocasiones, éstas pueden ser prevenidas con un buen diagnóstico. Entre las enfermedades cardíacas que causan estos decesos se encuentra la muerte súbita cardíaca (MSC), la cual de ser detectada con anticipación podría prevenir consecuencias indeseables en la salud del paciente, ya sea medicándolo o dándole una atención pre hospitalaria. Es por ello que se necesita desarrollar una metodología que permita monitorear el ritmo cardíaco del paciente y alertar con anticipación una posible arritmia para que éste tome sus precauciones y evitar que muera a causa de esta afección. Actualmente, existen muchas investigaciones sobre el tema de la detección anticipada de la muerte súbita cardíaca con el uso de procesamiento de la señal proveniente de un electrocardiograma (ECG) y herramientas computacionales para poder extraer la información relevante en este tema. Las metodologías desarrolladas previamente son capaces de alertar hasta 20 minutos antes de la fibrilación ventricular (la causa más recurrente en la MSC) suceda; evidentemente, entre más tiempo de anticipación se tenga es mejor para el paciente, por lo que es necesario crear una nueva metodología que pueda incrementar el tiempo de detección antes de dicho ataque y con mayor exactitud para así reducir la tasa de mortalidad. En el presente trabajo se desarrolla una metodología basada en la Descomposición Empírica de Modos (EMD) y en medidas no lineales tales como Fractal de Katz y Higuchi, Dimensión de conteo de cajas y Entropía de permutación para el diagnóstico anticipado de la muerte súbita cardíaca. Dicha metodología se realizó con el uso de la base de datos de señales ECG, adquiridas con un electrocardiograma de tipo Holter, la cual se encuentra en línea, es de acceso público y pertenece a la base de datos de Physionet, y fueron adquiridas en el hospital de Boston. Los resultados obtenidos permiten detectar la MSC 25 minutos antes de su aparición con una exactitud del 94%, por lo que puede considerarse que la metodología propuesta es una alternativa viable para la detección de este padecimiento.

Palabras clave: EMD, Dimensión Fractal, Redes Neuronales, MSC, Entropía.

DEDICATORIAS

Dedico esta tesis a Memo, QEPD, quien fue un gran amigo y me apoyo emocionalmente durante mi carrera y quien me enseño que los sueños sí se cumplen. Por ser la inspiración para realizar este trabajo.

A mi mamá, quien me ha brindado su apoyo y cariño durante toda mi vida, por darme todas las oportunidades para llegar a donde estoy hoy y por enseñarme a no rendirme; a mi papá, por ayudarme a crecer como persona y depositar su confianza en mi en todo momento.

A mis tias, María y Ana, por ayudarme cuando lo necesitaba y apoyarme en todas las decisiones.

A mi novio quien me apoyo todo el tiempo y me alentó a continuar, por darme su confianza y ayudarme en todo momento, por creer en mi y en mi capacidad para realizar este trabajo.

A Prisila quien siempre ha estado conmigo y me ha apoyado siempre, por no dejarme vencer.

AGRADECIMIENTOS

A mi mamá, Olivia, por ser el pilar central de mi vida y por confiar en mi y en cada paso que daba para terminar mis estudios, por ser mi confidente de vida y mi mejor amiga.

A mi papá, Juan Carlos, por darme las oportunidades que hicieron que hoy esté terminando mi carrera, por quererme siempre.

A mi tía, María, por ser una segunda mamá y quererme, por apoyarme sin condiciones, gracias por ayudarnos siempre.

A mi tía, Ana, por ser una amiga y darme consejos, por ayudarme con esos trabajos de química y materiales, por nunca dejarme rendir.

A mis hermanos, Juan Carlos, Carlos Alberto y Erika, gracias por ayudarme y enseñarme a luchar por lo que quiero.

A mis amigos, gracias por ayudarme cuando lo necesitaba, por darme su cariño y comprensión.

A mis docentes, de quienes aprendí el gusto por la ingeniería, por brindarme las herramientas y conocimientos durante mi paso por la universidad. En especial, a mi director de tesis, el Dr. Carlos Pérez, por su orientación y su ayuda para la culminación de este proyecto; al Dr. Juan pablo Amezcuita, por su orientación y compromiso con este trabajo; al Dr. Martín Valtierra, por sus consejos y mejoras en el trabajo; y al M.C. Eduardo Segoviano, por su compromiso y apoyo durante el cauce de este trabajo.

TABLA DE CONTENIDOS

1.	INTRODUCCIÓN.....	11
1.1	ANTECEDENTES.....	12
1.2	DESCRIPCIÓN DEL PROBLEMA.....	16
1.3	JUSTIFICACIÓN.....	17
1.4	HIPÓTESIS Y OBJETIVOS.....	18
1.4.1	<i>Hipótesis.....</i>	<i>18</i>
1.4.2	<i>Objetivo General.....</i>	<i>19</i>
1.4.3	<i>Objetivos Particulares.....</i>	<i>19</i>
1.5	PLANTEAMIENTO GENERAL DEL PROBLEMA.....	19
2.	REVISIÓN DE LITERATURA.....	22
2.1	SEÑALES ECG.....	22
2.2	TIPOS DE SENSORES PARA LA MEDICIÓN DE SEÑALES ECG.....	24
2.3	TÉCNICAS PARA EL PROCESAMIENTO DIGITAL DE SEÑALES.....	25
2.3.1	<i>Descomposición Empírica de Modos (EMD).....</i>	<i>26</i>
2.3.2	<i>Medidas no lineales.....</i>	<i>27</i>
2.3.3	<i>Análisis de varianza (ANOVA).....</i>	<i>31</i>
2.3.4	<i>Redes Neuronales.....</i>	<i>32</i>
2.4	MATLAB®.....	34
3.	METODOLOGÍA PROPUESTA.....	37
3.1	METODOLOGÍA.....	37
3.2	MATERIAL.....	39
3.3	ANÁLISIS EN TIEMPO DE UNA SEÑAL UTILIZANDO LA TÉCNICA EMD.....	40
4.	RESULTADOS OBTENIDOS.....	44
4.1	RESULTADOS.....	44
4.2	DISCUSIÓN DE RESULTADOS.....	52
5.	CONCLUSIONES Y PROSPECTIVAS.....	56
5.1	CONCLUSIONES.....	56
5.2	PROSPECTIVAS.....	56

6. REFERENCIAS 57

ÍNDICE DE FIGURAS

Figura 1.1 Planteamiento general del problema.....	20
Figura 2.1 Forma de onda de la señal eléctrica del corazón, resultado de un electrocardiograma.....	23
Figura 2.2 Ilustración de un electrodo húmedo desechable.....	24
Figura 2.3 Gráfica de caja.....	32
Figura 2.4 Arquitectura de un nodo o neurona en redes neuronales.....	33
Figura 2.5 Estructura de un perceptrón multicapa con dos capas ocultas.....	34
Figura 2.6 Ventana principal de MATLAB ®.....	35
Figura 3.1 Diagrama a bloques de la metodología propuesta.....	37
Figura 3.2 Señales a analizar (a) Sana y (b) con MSC.....	40
Figura 3.3 Señal sintética (a) Sin ruido, (b) Con 10 dB de ruido.....	41
Figura 3.4 IMFs obtenidas de la señal ilustrada en la figura 3.3	42
Figura 4.1 IMFs de un paciente (a) Sano y (b) con MSC.....	44
Figura 4.2 Valor de P para la IMF 1 de los 5 indicadores.....	45
Figura 4.3 Valor de P para la IMF 2 de los 5 indicadores.....	46
Figura 4.4 Valor de P para la IMF 3 de los 5 indicadores.....	46
Figura 4.5 Valor de P para la IMF 4 de los 5 indicadores.....	47
Figura 4.6 Valor de P para la IMF 5 de los 5 indicadores.....	47
Figura 4.7 Valor de P para la IMF 6 de los 5 indicadores.....	48
Figura 4.8 Distribución ANOVA de valores para a) EP de la IMF 5 y b) FH para la IMF 3.....	49

ÍNDICE DE TABLAS

Tabla 3.1 Información de las bases de datos.....	39
Tabla 4.1 Valores de promedio, desviación estándar y valor P de los dos indicadores (EP y FH) para los 25 minutos de ambas señales ECG.....	49
Tabla 4.2 Muestra la exactitud, obtenida con la metodología propuesta por minuto.....	51
Tabla 4.3 Resumen de trabajos anteriores que utilizan la misma base de datos.....	53

CAPÍTULO 1

Introducción

1. INTRODUCCIÓN

En la actualidad, una de las principales causas de mortalidad en la sociedad son las enfermedades cardíacas (OMS, 2018), ya que alrededor del 50% de todas las muertes a nivel mundial son ocasionadas por enfermedades cardiovasculares; por otra parte, un 12% de éstas son muertes naturales o muertes repentinas. (Engelstein y Zipes, 1998; Zipes et al., 2006; Myerburg et al., 2009; Adabag et al., 2010; Rea y Page, 2010). Estas enfermedades, de manera general, pueden ser arritmias o cardiomiopatías, por lo que, la detección temprana para el diagnóstico de éstas permitiría disminuir la tasa de muertes anuales a nivel mundial y local, con los consecuentes beneficios que esto conllevaría, tanto económicos como sociales, así como la mejoría en la calidad de vida de los pacientes con estas afecciones.

De las enfermedades cardíacas, la muerte súbita cardíaca (MSC) se caracteriza por provocar un paro cardíaco súbito a consecuencia de arritmias cardíacas tales como la fibrilación ventricular (FV), taquicardia ventricular o cardiopatía isquémica, en personas que pueden presentar o no enfermedades cardíacas previas al ataque. La FV representa un 20% del total de las muertes súbitas cardíacas y es conocida como la causa principal de la MSC (Pagidipati and Gaziano, 2013). La FV se caracteriza por una desorganización en la actividad eléctrica en los ventrículos del corazón, lo que lleva a que la sangre no sea bombeada eficientemente a todo el cuerpo y puede desembocar en la muerte de la persona si no es detectada a tiempo. En México, no existen registro alguno de la incidencia y prevalencia de los casos de muerte súbita cardíaca, pero se puede hacer un cálculo que aproxime el número de víctimas que fallecen debido a esta afección; por ejemplo, en el año 2008 alrededor de 60,000 adultos fallecieron a causa de cardiopatías isquémicas (Asensio et al., 2005). Debe resaltarse que al menos el 30% de estas muertes fueron de forma súbita (Asensio et al., 2005); sin embargo, en Aguilera et al. (2012) se estima que en nuestro país el número de fallecimientos de forma súbita ronda alrededor de las 70,000 personas por año. En la MSC, la sangre no fluye al cerebro ni al organismo lo cual provoca una muerte dentro de pocos minutos si no se trata a tiempo (González-Hermosillo et al., 2004;

Fisherman et al., 2010; Kong et al., 2010; Bayés, 2011; Stecke, 2014). Para tratar esta enfermedad, la desfibrilación ventricular en conjunto con la reanimación cardiopulmonar son parte muy importante en estos casos debido a que aumenta las posibilidades de sobrevivir a estos ataques de manera elevada. (Link et al., 2011). Por estas razones, es de suma importancia hacer la detección de la MSC de manera incipiente ya que la detección anticipada permitiría recibir atención médica e incrementar la posibilidad de sobrevivir a estos ataques.

Desafortunadamente, las señales cardiacas o ECG que son generadas por el cuerpo humano son de naturaleza no estacionaria, de amplitud baja y se encuentran inmersas en una gran cantidad de ruido; lo que representa un gran reto para la mayoría de las técnicas tradicionales como la Transformada de Fourier y sus variantes para el análisis de este tipo de señales, ya que no están diseñadas para procesar este tipo de señales (Acharya et al. 2006). Otra razón que dificulta la temprana detección de la MSC es que la diferencia que existe entre la señal cardiaca del corazón de una persona sana y una con MSC es mínima (Ebrahimzaed et al., 2014). Por estos motivos, es necesario explorar nuevas técnicas que puedan procesar señales ECG con las características anteriormente mencionadas, ya que de esta manera se podrá determinar si puede ocurrir una fibrilación ventricular que conllevará a una muerte súbita cardíaca.

1.1 Antecedentes

Diversos trabajos han realizado el análisis de la señal cardiaca o electrocardiograma. Los trabajos que se presentan emplean las señales adquiridas en una recopilación de señales cardiacas de pacientes sanos y con riesgo de MSC en hospitales en Boston, Massachusetts, Estados Unidos. Shen et al. (2007) combinaron la transformada Wavelet junto con una red neuronal, para analizar las señales del corazón, obteniendo un 87.5% de tasa de detección correcta. Los autores efectúan una comparativa de métodos de entrenamiento de la red neuronal, donde los algoritmos de mínimos cuadrados, y retropropagación fueron empleados, obteniendo una eficiencia en la clasificación del 67.44% y 55.81% dos minutos antes

del evento de MSC, respectivamente, comparado con el resultado previo, que fue calculado usando el algoritmo Levenberg–Marquardt. James et al. (2008) realizaron un estudio aplicando métodos no lineales de dimensión de correlación de puntos (PD2i), en el cual todas las señales con fibrilación ventricular mostraron un valor del PD2i menor a 1.4, mientras que aquellas señales normales tenían un valor de 1.4. Para esto, debe analizarse una ventana de 15 a 30 minutos de la señal ECG. La exactitud con la que el método puede discriminar entre una persona sana y otra con riesgo de sufrir MSC no se menciona. Por otra parte, Elías et al. (2011) procesaron la señal de la variabilidad del ritmo cardiaco 4 minutos antes de que sucediera el evento cardiaco. Debe resaltarse que se dividió la señal en 4 intervalos, siendo el tiempo de cada intervalo de 1 minuto. A cada intervalo le fueron calculadas la media, desviación estándar, la raíz cuadrada de la media de la suma de las diferencias al cuadrado de los intervalos RR adyacentes, entre otros, para obtener características directamente en la señal en el tiempo; por otra parte, a cada intervalo le fueron extraídas las bandas de frecuencia (muy baja, baja y alta) así como la razón obtenida al dividir el espectro de potencia de las bandas de baja y alta frecuencia. Adicionalmente, los autores aplican a cada intervalo la transformada Wigner-Ville para obtener la información tiempo-frecuencia, donde se vuelven a obtener las bandas de frecuencia y se calcula el valor máximo, mínimo, la diferencia entre el máximo y el mínimo, la desviación estándar, entre otras características. Para cada grupo de características se emplea el algoritmo de componentes principales a fin de seleccionar aquellas que permitan hacer la distinción entre los pacientes sanos y con riesgo de tener la MSC. Como clasificadores, se emplearon un perceptrón multicapa así como el algoritmo K-means, donde los algoritmos obtuvieron una eficiencia de clasificación del orden del 74% con las características del dominio del tiempo, mientras que al emplear las características obtenidas en el dominio tiempo-frecuencia la eficiencia en la clasificación aumenta considerablemente, ya que se obtuvo que una clasificación correcta de más del 95% para ambos algoritmos, siendo el perceptrón multicapa el más eficiente, pues se obtuvo un resultado de más del 99% de pacientes correctamente clasificados.

En el trabajo de Manis et al. (2013) empleando las señales de 20 pacientes considerados sanos y 20 pacientes clasificados como con alto riesgo de padecer un evento de MSC, adquiridas en un experimento realizado en la Universidad de Atenas, se analizaron métodos lineales, como métodos estadísticos, geométricos, análisis de frecuencia y métodos no lineales tales como la entropía aproximada y el exponente de Hurst. El objetivo de su trabajo es clasificar a sus pacientes en dos grupos: aquellos con bajo riesgo de sufrir la MSC y los que tienen un alto riesgo de sufrir una MSC. Para este propósito utilizaron la variabilidad de ritmo cardíaco (VRC) empleando ventanas, de 15 a 20 minutos, no superpuestas de 1024 puntos. Como clasificadores optaron por comparar los algoritmos de máquinas de soporte vectorial (MSV) y bosques aleatorios (BA), dando como resultado que el MSV tiene una eficiencia del 87.5%, mientras que los BA tienen un 85%. En el trabajo de Rajendra et al. (2015) utilizaron la transformada discreta de wavelet para dividir la señal del corazón en bandas de frecuencia de la señal de variabilidad del ritmo cardíaco. Para extraer las características de cada banda de frecuencia, se emplean diversas medidas no lineales tales como el análisis de cuantificación de recurrencia y la complejidad de Kolmogorov. Como clasificadores utilizaron 4 métodos: el VMC, árbol de decisiones (AD), MSV y una red neuronal probabilística (RNP). Debe comentarse que emplearon el mismo patrón de análisis que los dos trabajos previos, obteniéndose los siguientes resultados: para primer minuto antes del evento de MSC una exactitud del 92.1% fue obtenida, mientras que en el minuto 2 se obtuvo el 86.8% de exactitud. Para el minuto 3 solamente se presentaron resultados con la RNP, obteniéndose un 81.5% de exactitud; mientras que en el último minuto se obtuvieron una eficacia del 86.8% con VMC y RNP. Recientemente, Ebrahimzadeh et al. (2019) hicieron un análisis de las mismas señales, en las cuales se les extrajeron intervalos de un minuto antes de la MSC, se removió el ruido de la señal y se extrajo una señal de la variación del ritmo cardíaco, para después extraerle características lineales como los son en el dominio del tiempo, en el dominio de la frecuencia, características en el dominio del tiempo-frecuencia por medio de la Transformada Wigner-Ville, y medidas no lineales, usando el método Poincaré, y el

análisis de fluctuación desmedida; como clasificador se utilizó el perceptrón multicapa. El algoritmo planteado obtiene una eficiencia del 90% para detectar un evento de MSC 13 minutos antes de que éste ocurra.

Dentro de la Universidad Autónoma de Querétaro (UAQ), se ha empezado a trabajar con señales provenientes del cuerpo humano. Saavedra (2008) realizó un análisis comparativo de métodos para estudiar los anchos de banda de un electroencefalograma aplicando la Transformada de Fourier (FT) y la Transformada Wavelet Discreta. Por otra parte, García (2011) desarrolló un sistema de reconocimiento de voz utilizando la FT y un perceptrón multicapa para lograr el reconocimiento de palabras. Recientemente, Loiza (2015) hizo un estudio sobre la relación del electrocardiograma y el síndrome isquémico coronario agudo (SICA) para crear una base de datos con señales de pacientes que hayan sufrido SICA; sin embargo, no fue posible generar una base de datos debido a que los pacientes fueron atendidos alrededor de dos horas después del inicio de los síntomas. Hernández (2015) desarrolló un sistema de adquisición de señales biométricas en roedores, en el cual se adquiere la señal del corazón mediante un ECG; este trabajo constó del diseño e implementación de la electrónica para obtener la señal de corazón del roedor utilizando un método no invasivo. En los últimos dos años, se dio un gran avance en el área biomédica dentro de la UAQ, debido a que Cruz (2018) desarrolló una metodología para la clasificación de imaginación motora usando señales electroencefalográficas mediante la descomposición empírica de modos completa y fractales, en el cual se propone una clasificación de un estado de reposo y las imaginaciones motoras (derecha e izquierda), en el cual se tiene una tasa de clasificación del 71.37%. Un año más tarde, Carrasco (2019) desarrolló un sistema de adquisición y procesamiento de señales eléctricas cardíacas empleando la Transformada de Fourier, utilizando LabVIEW para la visualización de la misma. Además, Pérez (2019) empleó la Transformada Wavelet y el uso de fractales para detectar de forma anticipada un evento epiléptico usando señales del corazón usando una base de datos publicada por el Hospital de Boston, obteniendo como resultado una detección anticipada de 5 minutos en un 95% de las ocasiones.

Como se aprecia, la universidad ha empezado a trabajar en el procesamiento de señales biomédicas, por lo que este trabajo es un avance dentro de este promisorio panorama. Como se observa en los trabajos internacionales anteriormente descritos, los mejores resultados se obtienen cuando técnicas tiempo-frecuencia, así como clasificadores no lineales son empleados. Así mismo, debe resaltarse que las metodologías planteadas no van más allá de cuatro minutos antes de que suceda la MSC. Evidentemente, existen más técnicas tiempo-frecuencias que deben ser exploradas para verificar su rendimiento, ya que de incrementarse posibilitaría el ir más allá de los cuatro minutos antes la MSC, con los consiguientes beneficios en términos de la mejora en la supervivencia de los pacientes.

1.2 Descripción del problema

El diagnóstico de enfermedades de manera anticipada es de suma importancia para poder tratarlas de una manera eficaz. En el caso de la MSC, una detección temprana ayudaría a reducir en gran número las personas que mueren por esta enfermedad cardíaca. Por lo tanto, las herramientas que ayuden a detectar o predecir eventos cardíacos son importantes hoy en día para poder disminuir la tasa de mortalidad de MSC en nuestro país.

Actualmente, el diagnóstico y detección de enfermedades cardíacas es de suma importancia ya que con ello podemos prevenir ataques que puedan llevar a la muerte o a una mala calidad de vida; además de poder acceder a un tratamiento adecuado para cada caso en el que se presente una afección cardíaca. El diagnóstico de la muerte súbita cardíaca puede realizarse con un procesamiento de la señal proveniente del electrocardiograma, una de las causas y una alteración notable en estas señales es la fibrilación ventricular con la cual se realiza una detección anticipada de la MSC. En este sentido, la señal eléctrica del corazón, en general, están presentes en ambientes sumamente ruidosos, además de tener una amplitud pequeña comparada con la amplitud del ruido. Por estas razones, diversos investigadores han utilizado distintas técnicas para extraer características desde métodos no lineales en el dominio de tiempo-frecuencia, transformada discreta

wavelet (TDW), la transformada de Fourier (TF), la transformada Wigner-Ville (TWD), entre otras. Cada estudio tiene sus ventajas y desventajas; por ejemplo, la TDW requiere una selección apropiada tanto de la ondoleta madre y el nivel de descomposición para la obtención de las bandas de frecuencia; por otra parte, la TF solamente puede analizar señales con una relación señal a ruido grande, además de tener una naturaleza estacionaria; mientras que la TWD puede generar frecuencias espurias si el kernel de transformación no está sintonizado. Adicionalmente, los trabajos presentados únicamente analizan la señal hasta 4 minutos antes del evento cardiaco.

Evidentemente, es necesario buscar metodologías que no requieran de una sintonización fina para obtener los mejores resultados posibles, además de explorar una mayor cantidad de minutos antes de que suceda el evento cardiaco.

1.3 Justificación

Actualmente, la MSC es una de las causas de decesos en el mundo que afecta a un gran número de personas y es importante prevenir dichos ataques para poder disminuir las muertes por esta afección, ya que la detección con anticipación puede ser determinante para su prevención, además de incrementar las posibilidades de sobrevivir a estos ataques con una reanimación cardiopulmonar. Aún con promociones de la salud y los cuidados que debemos tomar en cuenta para no caer en el grupo susceptible de dicha enfermedad, es importante hacer uso de las tecnologías para poder monitorear la señal eléctrica del corazón y poder hacer predicciones de ésta.

El diagnóstico de enfermedades de manera anticipada es de suma importancia para poder tratarlas de una manera eficaz. En el caso de la MSC, una detección temprana ayuda a reducir en gran número las personas que mueren por esta enfermedad cardíaca. Por lo tanto, las herramientas que ayuden a detectar o predecir eventos cardiacos son importantes hoy en día para poder disminuir la tasa de mortalidad de MSC en nuestro país.

Las metodologías ya disponibles tienen como desventaja el poco tiempo antes al episodio de la fibrilación ventricular (4 minutos), y si bien es útil, se desea llegar lo más atrás del inicio del episodio para poder incrementar el porcentaje de éxito de sobrevivencia y así, disminuir el número de muertes en México y el mundo y mejorar la calidad de vida de las personas que cuentan con estas afecciones causantes de la muerte súbita cardíaca, ya que gracias a la detección temprana se puede dar reanimación cardiopulmonar (RCP) y con ello aumenta la posibilidad de revertir a un ritmo sinusal, además la RCP prolonga la ventana de tiempo para obtener una desfibrilación exitosa, ya que la supervivencia extra hospitalaria para esta afección es en promedio del 5%. Por tal motivo, estos hechos justifican el hecho de estudiar metodologías que permitan detectar en una etapa más incipiente el evento cardíaco.

Por otra parte, existe la necesidad de explorar otras técnicas de análisis de señales en el dominio tiempo-frecuencia, como la descomposición empírica de modos, así como el uso de algunas características no lineales que pueden extraerse de la señal ECG, tales como los fractales y entropías, ya que en conjunto pueden ofrecer una solución que permita identificar los pacientes que puedan sufrir de MSC con una carga computacional moderada, lo que justifica este trabajo.

1.4 Hipótesis y objetivos

1.4.1 Hipótesis

Mediante la fusión de la Descomposición Empírica de Modos (EMD) con medidas no lineales, tales como el fractal de Higuchi y la entropía de permutación, es posible generar una metodología que permita hacer la detección de un evento cardíaco 25 minutos antes de que éste suceda, siendo esta metodología capaz de superar los resultados presentados por otros trabajos en el estado del arte.

1.4.2 Objetivo General

Proponer y desarrollar una metodología basada en la EMD, el fractal de Higuchi y la entropía de permutación para la detección de eventos cardíacos, empleando las señales ECG, minutos antes de que éstos sucedan.

1.4.3 Objetivos Particulares

- ✓ Desarrollar un algoritmo que divida la señal cardíaca del corazón en intervalos de 1 minuto empleando el software MATLAB para su posterior análisis.
- ✓ Programar la técnica de la Descomposición Empírica de Modos (EMD) haciendo uso del software MATLAB para procesar y descomponer una señal en tiempo en sus diferentes bandas de frecuencia.
- ✓ Programar diversas medidas no lineales, tales como la entropía de Shannon y de permutación, los fractales de Katz, Higuchi y Dimensión de Cajas, haciendo uso del software MATLAB, para estimar la complejidad de una señal en el dominio del tiempo a fin de hacer la clasificación entre pacientes sanos y enfermos.
- ✓ Identificar las medidas más discriminantes para realizar un análisis estadístico mediante ANOVA con el fin de validar la metodología propuesta y obtener una clasificación eficiente.
- ✓ Desarrollar una metodología mediante la conjunción de la EMD y las medidas no lineales que permita indicar si una persona presenta un evento cardíaco 25 minutos antes de que éste suceda o no.

1.5 Planteamiento General del Problema

La Figura 1.1 muestra de manera gráfica el planteamiento general del problema que se trata en el presente trabajo.



Figura 1.1 Planteamiento general del problema

Como se aprecia en la Figura 1.1, para detectar el problema planteado se requiere ejecutar 5 pasos: (1) obtener señales de ECG de personas sanas y con MSC de un banco de datos de Physionet con dirección electrónica: <https://physionet.org/physiobank/database/nsrdb/> y <https://physionet.org/physiobank/database/mitdb/>, respectivamente, (2) dividir las señales en intervalos de 1 minuto antes de que se presente la fibrilación ventricular; (3) a cada señal generada se aplica un método de transformación tiempo-frecuencia para obtener las componentes individuales de cada señal; (4) a cada componente individual se le aplican diversas medidas no lineales a fin de verificar el rendimiento de cada una de ellas, con el objeto de seleccionar la que permita distinguir entre una persona sana y una con riesgo de sufrir muerte súbita cardíaca y (5) crear un clasificador de señales donde se pueda diferenciar una señal sana de una señal la cual contenga una perturbación correspondiente a la fibrilación ventricular y ser capaz de detectar el problema cardíaco con anterioridad.

CAPÍTULO 2

Revisión de literatura

2. REVISIÓN DE LITERATURA

En este capítulo se presenta la consulta bibliográfica y se muestran los fundamentos teóricos que apoyan la aplicación de cada parte de la metodología propuesta. En particular, se describen las señales eléctricas del corazón, así como de las técnicas computacionales para procesar dichas señales, la red neuronal utilizada para la clasificación; por último, se realiza una breve presentación del software utilizado llamado MATLAB®.

2.1 Señales ECG

Una señal electrocardiográfica (ECG) representa el registro de la activación cardíaca generada por las fibras musculares del corazón. Es usada para investigar diferentes cardiopatías del corazón incluyendo arritmias, así como alteraciones de la conducción eléctrica (Gacek, 2012). En el año de 1902, Willen Einthoven desarrolló el primer electrocardiograma, el cual era un método no invasivo para diagnosticar condiciones cardíacas con aplicaciones clínicas (Ebrahimzadeh, 2014).

Las señales ECG se crean debido a las diferencias de los potenciales de las células que se encuentran en el miocardio, grupo de células musculares especializadas, y se genera una contracción; los encargados de generar y transmitir los impulsos eléctricos en el corazón son el nodo sino-auricular (SA), conocido también como el marcapasos fisiológico debido a que genera el impulso eléctrico, el nodo atrio-ventricular (AV), el cual recibe las señales del nodo SA y las transmite al Haz de His, quien tiene presencia en ambos lados del corazón para después pasar a las ramificaciones o fibras de Purkinje (Swapna et al., 2012).

El ciclo cardíaco presenta dos fases para que el corazón cumpla con su función de bombeo de sangre a todo el cuerpo: (1) la *diástole* es producida cuando los ventrículos se encuentran relajados y se llenan de sangre la cual se tendrá que expulsar, mientras que (2) la *sístole* se genera cuando éstos se contraen provocando la eyección de la sangre contenida (García, 2009). La señal del corazón tiene una forma de onda característica la cual se ilustra en la Figura 2.1.




Figura 2.1 Forma de onda de la señal eléctrica del corazón, resultado de un electrocardiograma.

A partir de la figura, se pueden observar las diferentes ondas e intervalos que describen el comportamiento eléctrico y mecánico del corazón, los cuales describen las fases de despolarización y repolarización (Vera et al., 2006):

- La onda P es la primera onda que se percibe en un ECG y es el resultado de la despolarización de las aurículas.
- El segmento PQ corresponde a los impulsos eléctricos en el nodo sino auricular, el haz de His y las fibras de Purkinje. Este segmento expresa el tiempo transcurrido desde la despolarización auricular hasta el inicio de la despolarización ventricular.
- El complejo QRS corresponde a la despolarización ventricular.
- La onda T representa la repolarización ventricular, después de esta se encuentra la onda U, la cual es de la misma polaridad y se sugiere que es causada por potenciales posteriores que se generan por una retroalimentación mecánico-eléctrica.
- El intervalo QT corresponde entonces a la duración del potencial de acción ventricular y a la repolarización. El intervalo TP es el periodo

en el cual las aurículas y ventrículos están en la fase diastólica (periodo de relajación después de la contracción del músculo).

- El intervalo RR representa un ciclo cardíaco y es utilizado para calcular la frecuencia cardíaca.

2.2 Tipos de sensores para la medición de señales ECG.

La conductividad eléctrica del cuerpo humano involucra iones tanto negativos como positivos; por lo tanto, para poder captar las señales bioeléctricas del cuerpo humano, y del corazón en particular, es necesario contar con un instrumento que haga la función de una interfaz entre el cuerpo humano y el equipo de medición (electrocardiógrafo). Este instrumento se conoce como *electrodo* (Neuman, 2009). Existen dos tipos de electrodos con los cuales se puede recuperar la señal ECG: (1) los electrodos de superficie, los cuales son no invasivos ya que únicamente hacen contacto con la piel del paciente y (2) los electrodos de aguja o invasivos son aquellos que necesitan de cirugía para poder ser colocados en el cuerpo del paciente (Córdova, 2013).

En particular, los electrodos de superficie se dividen en dos grupos: (1) electrodos secos, los cuales hacen contacto directamente con la piel del paciente, y (2) electrodos húmedos, a los cuales se le pone un gel conductor antes de colocarlos en la piel del paciente con el objetivo de mejorar la conductividad eléctrica. Generalmente, los electrodos húmedos están fabricados de una capa metálica ya sea de plata, aleación plata-níquel, oro o platino (Neuman, 2009). Un ejemplo de ellos se muestra en la Figura 2.2




Figura 2.2 Ilustración de un electrodo húmedo desechable.

La medición del ECG mediante el uso de electrodos se ve afectada por el ruido y perturbaciones los cuales se pueden generar por:

- Cambios en la impedancia del electrodo corporal como resultado de procesos físico-químicos en esta región.
- Movimientos del paciente.
- Los cambios de la posición del corazón y los electrodos causados por movimientos respiratorios del paciente.
- Contracción de los músculos esqueléticos causada por el movimiento del paciente o una temperatura inapropiada del ambiente.

Estas perturbaciones son muy difíciles de tratar debido a su amplio espectro de frecuencia, cuya frecuencia se solapa con la frecuencia de la señal del ECG (Fernandez-Chimeno et al., 2006). Una buena colocación de los electrodos reduce estas perturbaciones generando una buena lectura de las señales del corazón, ayudando a tener una mejor visualización. Sin embargo, a pesar de la correcta colocación de los electrodos, el ruido que se genera por los electrodos no se elimina en su totalidad, lo que pudiera distorsionar la señal ECG, por lo que es necesario efectuar el procesamiento digital de la señal ECG para mitigar el ruido remanente que la señal pudiera contener.

2.3 Técnicas para el Procesamiento Digital de Señales

El procesamiento digital de señales (PDS) es una rama de la ingeniería electrónica encargada de la representación, transformación, manipulación de señales y de la información contenida en ellas. Además, permite manejar la amplitud en forma discreta siendo necesario para poder procesar la señal en una computadora (Vignolo, 2008).

En particular, una señal ECG puede analizarse con técnicas en el dominio de la frecuencia tales como la transformada de Fourier (FT) o el algoritmo de Clasificación Múltiple de Señales (MUSIC); sin embargo, deben comentarse algunos puntos de que las técnicas tienen. Por ejemplo, la FT requiere que la señal tenga una relación señal a ruido grande para poder entregar buenos resultados,

situación que no siempre es posible pues la señal ECG puede contaminarse durante la adquisición. Por este motivo, se emplea el algoritmo MUSIC, que tiene una mayor capacidad para procesar señales ruidosas; pero, para su utilización se requiere conocer cuántas frecuencias están contenidas en la señal, concepto que no es posible de conocer *a-priori*. Por estas razones, los algoritmos tiempo-frecuencia se emplean pues tienen características más apropiadas para el análisis de la señal ECG (Amezquita-Sanchez et al, 2018). De todos estos, la descomposición empírica de modos (EMD) permite extraer las componentes individuales o bandas de frecuencia de la señal ECG de una manera eficiente, sin requerir el conocimiento previo de características previas de la señal o el ajuste fino del algoritmo. Por estas razones, se hace uso de la EMD como técnica de pre-procesamiento de la señal ECG en este trabajo de tesis.

2.3.1 Descomposición Empírica de Modos (EMD)

El método de descomposición empírica de modos fue propuesto por Huang et al. (1998), es utilizado para procesar señales no lineales y transitorias, como las señales obtenidas de un electrocardiografo. Esta técnica permite descomponer una señal en el dominio del tiempo en un conjunto de bandas de frecuencia limitadas conocidas como *funciones de modo intrínseco* (IMF's, por sus siglas en inglés). En general, cada IMF contiene solamente una frecuencia. El proceso para adquirir las IMFs consiste en los siguientes pasos (Huang et al., 1998):

- Detectar los puntos máximos y mínimos de la señal original. Después, los puntos detectados se unen para obtener una envolvente superior y una envolvente inferior empleando una técnica de interpolación (comúnmente splines cúbicas); el promedio de ambas curvas creadas por la interpolación se le denomina m_1 y se resta de la señal original para obtener una señal nueva.

$$h_1(t) = x(t) - m_1(t) \quad (2.1)$$

- Contar el número máximos y mínimos presentes en la señal $h_1(t)$. Si éstos son iguales o difieren en una unidad, se considera que se ha obtenido la primera banda de frecuencia; en caso contrario, usar $h_1(t)$ como nueva señal y aplicar el procedimiento descrito hasta encontrar la primera banda.
- Una vez obtenida la primera banda de frecuencia (IMF 1), la señal h_1 se resta de la señal original y se calcula el residuo r_1 de la siguiente manera:

$$r_1(t) = x_1 - c_1(t) \quad (2.2)$$

- Si la función r_1 es monótona, entonces no se pueden extraer más bandas de frecuencia, por lo que se termina el proceso. De no ser así, se continua con el proceso hasta estimar las demás IMFs. El proceso termina cuando r_1 se vuelve una señal monótona.

Cuando el proceso para, la señal original $x(t)$ se descompone en N IMFs, pudiendo expresarse la señal como:

$$x(t) = \sum_{n=1}^N C_n(t) + r(t) \quad (2.3)$$

Una vez obtenidas las diversas IMFs que la señal ECG tiene, es necesario extraer las características no lineales que tiene cada IMF, a fin de poder generar el clasificador que permita indicar si la persona está en riesgo de sufrir la MSC o no.

2.3.2 Medidas no lineales

Las señales del corazón se caracterizan por tener características no lineales (Amezquita-Sanchez et al., 2018), por lo cual es necesario utilizar técnicas de extracción de características que puedan procesar este tipo de señales. De manera general, las técnicas no lineales se basan en medir la complejidad de la forma de onda de las señales, donde se asume que conforme cambia la señal, también cambia su forma geométrica, y por ende, su complejidad. Algunas de estas técnicas son fractales y entropías, que a continuación se describen.

2.3.2.1 Dimensión fractal.

Se considera que una señal tiene auto-similitud cuando ésta es muy similar o igual a una parte de ella misma. En este sentido, la dimensión fractal (DF) permite estimar el grado de auto-similitud que tiene la señal a partir de la estructura geométrica que tiene la misma (Amezquita-Sanchez et al., 2018). Un valor bajo de la DF indica que la señal es poco compleja, es decir, no se repiten patrones; en cambio, un valor alto de DF es generado cuando la señal tiene una complejidad geométrica considerable. Para una señal en el tiempo, los valores de la DF oscilan entre 1 y 2. Dado que este trabajo considera la señal ECG como una señal compleja, la DF puede ser usada como un índice para determinar cambios en la señal ECG, dado que la alteración de la señal ECG generada por la MSC generará cambios en la geometría de ésta, lo que radicaría en la modificación del valor de la DF.

Para estimar la DF, se emplean 3 métodos descritos en las siguientes subsecciones.

2.3.2.1.1 Fractal de Katz.

El cálculo de la dimensión fractal (FD, por sus siglas en inglés) se deriva directamente de la forma de onda, eliminando la etapa de pre-procesamiento de crear una secuencia binaria. El algoritmo de Katz se calcula usando el siguiente procedimiento (Katz, 1988).

$$D = \frac{\log_{10}(L)}{\log_{10}(d)} \quad (2.4)$$

donde L es la longitud de la curva o la suma de las distancias entre puntos sucesivos (Ecuación 2.2), y d es el diámetro de la curva y puede ser expresado de acuerdo a.

$$L = \sum_{i=1}^N \text{dist}(S_i, S_{i+1}), i = 1, \dots, N - 1 \quad (2.5)$$

$$d = \max\{\text{dist}(S_1, S_i), i = 1, \dots, N\} \quad (2.6)$$

donde N es el número de pasos en la curva. Por lo tanto, la ecuación queda de la siguiente forma:

$$KFD = \frac{\log_{10}\left(\frac{L}{a}\right)}{\log_{10}\left(\frac{d}{a}\right)} \quad (2.7)$$

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

2.3.2.1.2 Algoritmo de Higuchi

Esta FD fue creada por Higuchi (1988). Para realizar su cálculo se definen nuevas series de tiempo, empleando:

$$X_m^k = \left[x_m + x_{m+k} + x_{m+2k} + \dots + x_{m+\left[\frac{N-m}{k}\right]} \right] \times m = ,1,2, \dots k \quad (2.8)$$

donde k indica el intervalo de tiempo discreto entre puntos y m es el punto de muestreo inicial.

Para cada serie nueva de tiempo (X_m^k), se calcula el promedio normalizado:

$$L(X_m^k) = \left(\frac{N-1}{Mk} \sum_{i=1}^M |X_m^k[i] - X_m^k[i-1]| / k \right) \quad (2.9)$$

donde el factor de normalización es $M = \frac{N-m}{k}$.

Posteriormente, se obtiene la longitud total $L(k)$ por medio de la media de la longitud de las series:

$$L(k) = \sum_{m=1}^k L_m(k) \quad (2.10)$$

Inmediatamente, se incrementa en una unidad el valor de k . Si la condición $k < k_{max}$ se cumple, los pasos previos se repiten. La variable k_{max} es el salto máximo entre muestras y 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, dicho valor de la pendiente de esa línea representa el fractal de Higuchi.

2.3.2.1.3 Algoritmo de Dimensión de Caja

Es un método basado en un cociente de logaritmos y se determina como el algoritmo natural de la suma de las diferencias entre dos puntos consecutivos de

una señal $x(t)$ en un determinado intervalo de tiempo, el cual es dividido por el logaritmo natural del periodo del tiempo establecido (Wang ,2005).

La dimensión fractal por dimensión de cajas se define por ecuación:

$$BCD \cong - \frac{\ln[\sum_{i=1}^{N-1} |x_{i+1} - x_i| / \Delta t]}{\ln(\Delta t)} \quad (2.11)$$

donde N es el número de muestras de la señal de la serie de tiempo x que se va a analizar y Δt es el intervalo de tiempo de muestreo.

2.3.2.2 Entropía

De manera general, la entropía es una aproximación para cuantificar la medida de aleatoriedad de una señal en el tiempo. Para este trabajo, la entropía es usada para detectar el comportamiento aleatorio que potencialmente puede tener la señal ECG, ya que entre más “aleatoriedad” tenga la señal, se espera que esté más cercano el evento MSC. En este trabajo se analizan dos aproximaciones de la entropía, mismas que describen en las siguientes subsecciones.

2.3.2.2.1 Entropía de Shannon.

La entropía de Shannon (ES) es una medida no lineal en señales dinámicas y proporciona una medida del contenido de información promedio asociado con la aleatoriedad de datos encontrada en una señal o evento (Shannon, 1948). Ésta se puede calcular usando:

$$SE = - \sum_i p(x_i) \log_2(p(x_i)) \quad (2.12)$$

donde $p(x_i)$ es la probabilidad de ocurrencia de la muestra x_i en la señal. Usualmente, los valores mínimos y máximos de la señal dependen de la resolución del convertidor analógico-digital empleado (Mejia-Barron et al., 2019)

2.3.2.2.2 Entropía de Permutación.

La entropía de Permutación (EP) es una medida de complejidad para series temporales basadas en la comparación valores vecinos. La EP fue propuesta por Bandt y Pompe en 2002, y explica la información temporal contenida en una serie

de tiempo; Las ventajas sobre las otras entropías son la simplicidad, la robustez y el muy bajo costo computacional (Zanin, 2012).

La serie temporal se mapea realizando en una secuencia simbólica que describe la relación entre valores presentes y un número equidistante de valores pasados. El mapeo se logra primeramente poniendo una serie de tiempo $x(t), t = 1, 2, 3, \dots$ en un espacio m -dimensional, como se muestra a continuación:

$$X(t) = [x(t), x(t + \tau), \dots, x(t + m\tau)] \quad (2.13)$$

donde m es la dimensión para generar el espacio y τ es el intervalo de tiempo (Nicolaou, 2012).

Una vez calculadas las características descritas anteriormente, es necesario saber cuáles de ellas permiten distinguir entre el paciente sano y el paciente con MSC lo más certero posible. Para esto, es necesario saber cuáles de las características aportan información diferente. Eso se hace haciendo un análisis estadístico.

2.3.3 Análisis de varianza (ANOVA)

ANOVA es una técnica que utiliza la estadística para evaluar si dos conjuntos de datos comparten información. Si no la comparte, se dice que los dos conjuntos son independientes; en caso contrario, las variables son dependientes (Bakieva et al., s.f).

ANOVA genera un diagrama de cajas, mostrado en la Figura 2.3, que permite analizar los datos de manera gráfica mediante una caja. La caja es la representación visual que permite expresar la concentración de los datos alrededor de la mediana (línea negra de la Figura 2.3). En este sentido, la altura de la caja depende de los valores que se concentren entre el 25 y 75% de los valores que la variable en estudio toma. Los bigotes representan los valores mínimos y máximos que la variable tiene. En conjunto, el diagrama de cajas permite observar los valores límite que la variable toma. Para este trabajo, se busca que las cajas se traslapen lo mínimo posible, ya

que esto indica que las variables tienen valores diferentes, lo que implica que aportan información para permitir la distinción entre dos condiciones posibles.

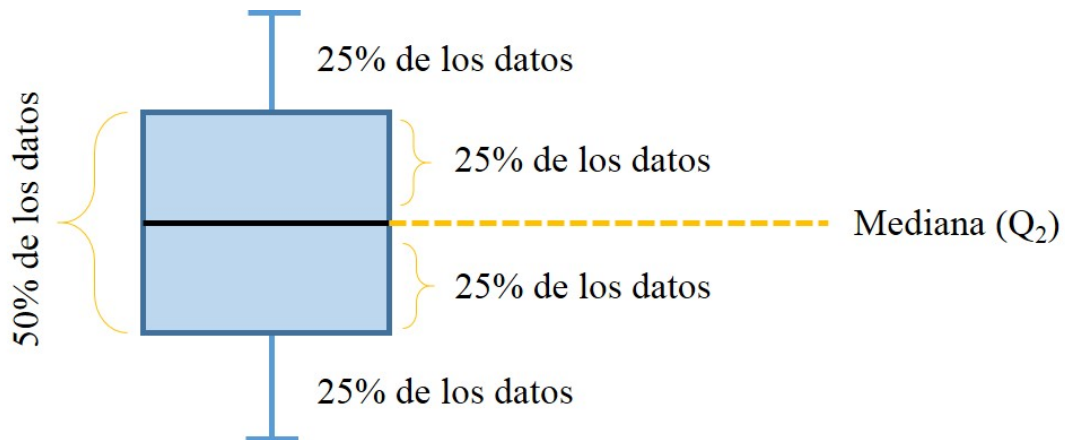


Figura 2.3 Gráfica de caja.

Si bien es posible hacer la distinción arriba mencionada únicamente con el diagrama de cajas, sería deseable el emplear un criterio numérico. En este sentido, ANOVA también calcula el valor de probabilidad (P) el cual toma valores entre 0 y 1, donde 0 significa que los dos conjuntos son independientes, mientras que el 1 indica que los dos conjuntos son dependientes entre sí. Dicho parámetro indica la capacidad para diferenciar entre los grupos que se están estudiando (Amezquita-Sanchez et al., 2016), donde se busca emplear el par de conjuntos de datos que tengan el valor P más cercano a 0, ya que de esta manera es posible plantear el clasificador con la mayor eficiencia posible. Un clasificador que cumple con esta característica es el uso de una red neuronal.

2.3.4 Redes Neuronales

Las redes neuronales (Artificial Neural Network o ANN, por sus siglas en inglés) tienen el fin de simular la estructura neurológica del cerebro humano y la capacidad de éste de aprender y resolver problemas por sí solo. (Hernández-Vargas, 2014). La estructura de una ANN (ver Figura 2.4) está conformada por nodos, las cuales simulan las neuronas, y están organizados por capas, que varían en número dependiendo de la aplicación, pero siempre deben existir: (1) la capa de entrada y (2) la capa de salida. (López-Ramírez, 2016). A un nodo, llegan señales

de entrada las cuales serán multiplicadas por pesos (coeficientes), los cuales se ajustan con el proceso de aprendizaje, inmediatamente, se suman estas señales nuevas y luego pasan por una función de transferencia para así, producir una señal de salida. La función de activación es la suma ponderada de las entradas de la neurona; la más utilizada es la función sigmoide (Agatonovic-Kustrin, 2000).

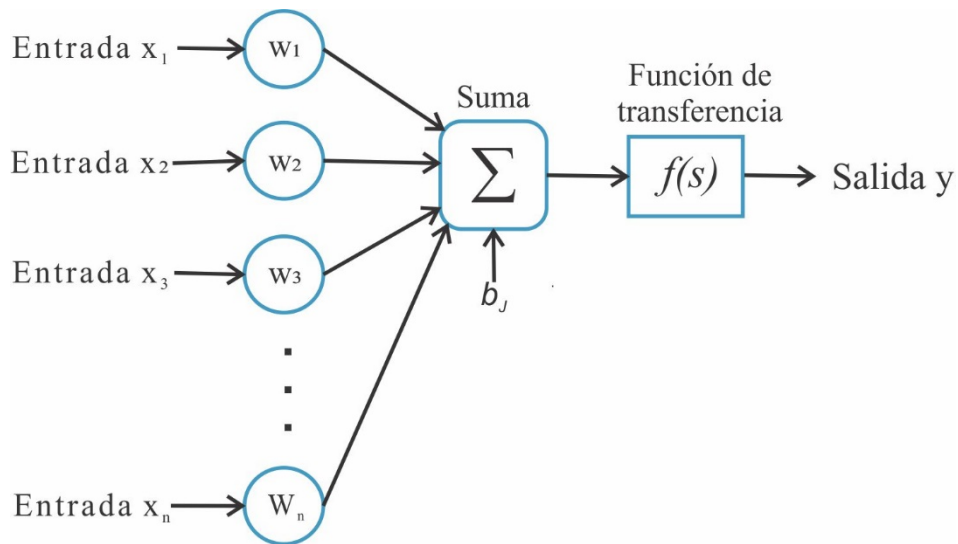


Figura 2.4 Arquitectura de un nodo o neurona en redes neuronales.

El perceptrón multicapa (MLP, por sus siglas en inglés) es un tipo de red neuronal, consiste en un sistema simple de nodos interconectados (Gardner, 1998) como se muestra en la Figura 2.4, donde x corresponde a las entradas y y a las salidas.




Figura 2.5 Estructura de un perceptrón multicapa con dos capas ocultas.

Durante el desarrollo de una red neuronal hay dos etapas fundamentales: (1) Etapa de entrenamiento, donde se ingresan las entradas y las salidas, y los pesos se van ajustando con el factor de aprendizaje, así hasta obtener los resultados que el usuario busca. Mientras que la generación de aprendizaje para nuevos casos y el que la red no se quede ciclada con estos datos se buscan en la (2) etapa de validación. (López-Ramírez, 2016).

2.4 MATLAB ®

MATLAB ® (MATrix LABoratory) es una herramienta computacional de alto nivel, desarrollada en 1984 por Cleve Moler and Jack Little. Integra en el mismo entorno un software de computación, graficación, y programación. Además, tiene una notación matemática muy fácil (Baez-López, 2010).

Algunas de las aplicaciones más comunes del uso de MATLAB ® son:

- Procesamiento de señales e imágenes.
- Clasificación de datos mediante inteligencia artificial.

- Diseño y análisis de sistemas de control

MATLAB cuenta con una ventana principal, dividida en diferentes secciones que permiten navegar e interactuar con el programa (ver Figura 2.5)

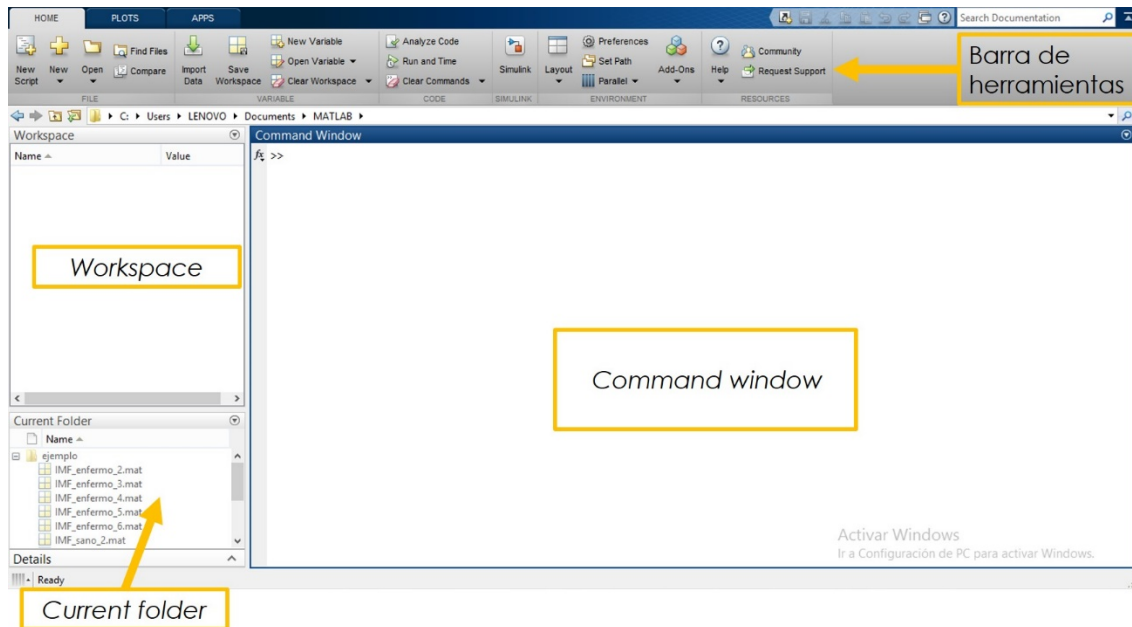


Figura 2.6 Ventana principal de MATLAB ®

- *Current folder*: Muestras los archivos contenidos en la carpeta en uso (actual).
- *Workspace*: Muestra las variables y sus valores, nos permite ejecutarlos y visualizarlos.
- *Editor*: Es la ventana en la cual podemos visualizar códigos, editarlos y ejecutarlos.
- *Barra de herramientas*: Se encuentra en la parte superior de la ventana principal, en ella encontramos los botones que nos permiten crear nuevos archivos .m (extensión de MATLAB), abrir archivos existentes, opciones específicas para las gráficas, y paquetes de software (llamados toolbox) que nos permiten procesar imágenes, crear redes neuronales, entre otras aplicaciones.

CAPÍTULO 3

Metodología propuesta

3. METODOLOGÍA PROPUESTA

Este capítulo presenta la metodología propuesta para hacer la detección de un evento de MSC hasta 25 minutos antes de que éste suceda.

3.1 Metodología

La metodología propuesta de este trabajo se encuentra en la Figura 3.1.

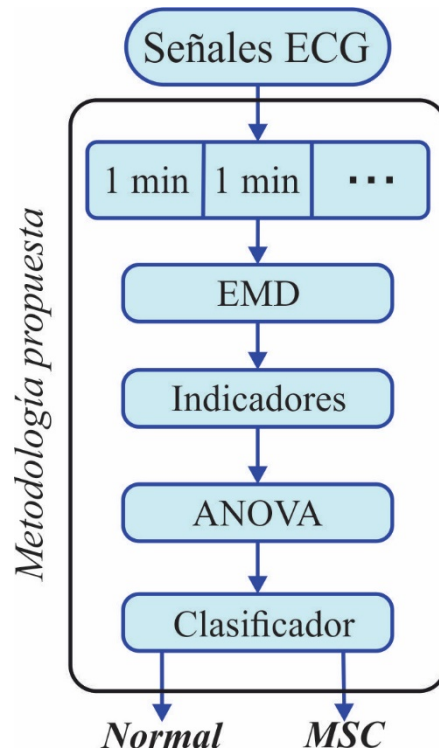


Figura 3.1 Diagrama a bloques de la metodología propuesta.

Como se aprecia, la metodología propuesta consta de 5 etapas, que se describen a continuación:

1. Segmentación de señales. Las señales ECG de ambas condiciones (sana y con MSC) son segmentadas en ventanas de un minuto hasta 25 minutos antes de que suceda el evento de MSC. Se empleó este tamaño ya que en la literatura consultada se indica que es una ventana adecuada que permite identificar características en la señal (Fishman et al., 2010).

2. Preprocesamiento de la señal. Una vez obtenida esta segmentación, se aplica la EMD para obtener un conjunto de IMFs las cuales pueden contener características ocultas que contribuyan a la predicción de la MSC.

3. Extracción de características. En esta etapa se aplican diversos indicadores a cada una de las IMFs para posteriormente encontrar cuál de éstas es la que aporta la información que permita identificar entre una persona sana y una que sufrirá un infarto. Los indicadores empleados en este trabajo son, como ya se mencionó en el capítulo anterior: 1) Entropía de Shannon, 2) Entropía de permutación, 3) Fractal de Katz, 4) Fractal de Higuchi, y 5) Fractal de dimensión de cajas, los cuales han demostrado ser sensibles a la presencia de propiedades no lineales en una señal. (Amezquita-Sanchez et al., 2016).

4. Análisis Estadístico. Una vez obtenidos los indicadores, se utiliza el método estadístico ANOVA para encontrar cuál de ellos es el más significativo para los propósitos de este trabajo. ANOVA estima, en la plataforma de programación usada (MATLAB) dos parámetros: 1) Valor P y el 2) Índice de Discriminación de Fisher). Si bien estos indicadores indican la capacidad que tienen de discriminar entre las dos condiciones, usualmente se emplea el primero, cuyos valores están en el rango de 0 a 1, donde el 0 indica que las dos características son independientes y el 1 que las características no son independientes. En otras palabras, un valor lo más cercano a 0 indica que las características aportan información complementaria y, por tanto, pueden ser usadas para clasificar, mientras que un valor muy cercano a 1 indica que las características aportan la misma información, por lo que se debe de buscar otra (Amezquita-Sanchez et al., 2016). Evidentemente, se desea buscar las características que den el valor P más cercano a 0, pues esto permitiría construir un clasificador eficiente.

5. Clasificación. Finalmente, los indicadores seleccionados son utilizados como las entradas en la red neuronal, que es un perceptrón multicapa, para determinar la condición de cada señal de manera automatizada y así obtener una clasificación de las señales como sana o con riesgo de MSC hasta 25 minutos antes de que suceda el evento.

3.2 Material

Con el fin de probar y validar la metodología propuesta, las señales ECG usadas provienen de dos bases de datos internacionales. La primera es la base de datos Normal Sinus Rhythm (NSR), MIT/BIH-NSR (2018), en la cual se encuentran las señales de 18 pacientes, donde expertos del laboratorio de arritmias del hospital Beth Israelí en Boston confirmaron que los sujetos presentan un ritmo cardíaco normal; por lo tanto, dichas señales no contienen propiedades asociadas a la muerte súbita cardíaca. La segunda es la base de datos SCDH database MIT/BIH-SCDH (2018), que incluye 23 señales ECG de pacientes con muerte súbita cardíaca ocasionada por la fibrilación ventricular. Para todas estas señales, el episodio de la MSC está indicado el tiempo en el que ocurrió. Por consiguiente, este tiempo se utiliza como referencia a partir de ahí, tomar 25 intervalos de 1 minuto de esta señal para predecir la aparición de la MSC de una manera anticipada. Es importante recalcar que solo se utilizaron 20 señales para el análisis debido a que los 3 restantes pertenecen a sujetos que presentaron alteraciones cardíacas diferentes a la fibrilación ventricular como cardiopatía hipertrófica y taquicardia ventricular (las cuales son áreas de oportunidad para trabajos futuros). En la Tabla 3.1 se muestra el género y la edad de los grupos (normal y MSC) de las señales que se utilizan en el presente trabajo.

Tabla 3.1. Información de las bases de datos.

Base de datos	Grupo	Sujetos (género)	Edad
NSR	Normal	18 (13 mujeres)	35 ± 15
SCDH	MSC	23 (8 mujeres)	49.5 ± 32.5

Dado que las señales ECG corresponden a diferentes bases de datos, se deben tomar en cuenta algunos aspectos para la buena realización del trabajo. El primer aspecto a considerar son las frecuencias de las señales, las señales ECG de la base de datos SCD tienen una frecuencia de muestreo de 250 Hz, mientras que la frecuencia de muestreo de las señales ECG de la base de datos con personas de ritmo cardíaco normal es de 128 Hz; por lo cual, es necesario modificar la frecuencia

de muestreo la base datos SCD para que ambas tengan la misma frecuencia. La Figura 3.2 muestra ambas señales, (a) de una persona sana y (b) una persona con MSC. Como se observa, no hay diferencias visuales significativas entre las dos señales antes de que suceda el evento MSC, por lo que, para poder detectar las características ocultas, se utilizan ventanas de 1 minuto de tiempo. Aunque estas señales fueron monitoreadas durante 24 horas únicamente 25 minutos, antes del evento de muerte súbita cardíaca, fueron analizados. Cabe resaltar que, en el caso de los pacientes sanos, se escogió el intervalo de 1 minuto de manera aleatoria, pues la señal no presenta ninguna alteración asociada a la MSC.




Figura 3.2. Señales a analizar (a) Sana y (b) con MSC.

3.3 Análisis en tiempo de una señal utilizando la técnica EMD.

A fin de ejemplificar el uso de la metodología propuesta, se construye una señal sintética cosenoidal, basada en la siguiente ecuación:

$$x(t) = A * \cos(2\pi ft) \quad (3.1)$$

Empleando esta ecuación, se generan dos señales cuyas frecuencias son de 150 y 200 Hz, respectivamente, con una frecuencia de muestreo de 2 kHz. La señal dura un tiempo de 10 s, resultando en 20000 muestras. Ya construidas estas señales, se suman, lo que se ilustra en la Figura 3.3 (a). A fin de simular las condiciones de ruido, a la señal se le suma ruido blanco para generar una relación señal a ruido de 10 dB, misma que se muestra en la Figura 3.3 (b).




Figura 3.3 Señal sintética (a) Sin ruido, (b) Con 10 dB de ruido.

Una vez obtenida la señal, se aplica el algoritmo EMD, obteniéndose 8 IMFs, que se ilustran en la Figura 3.4.

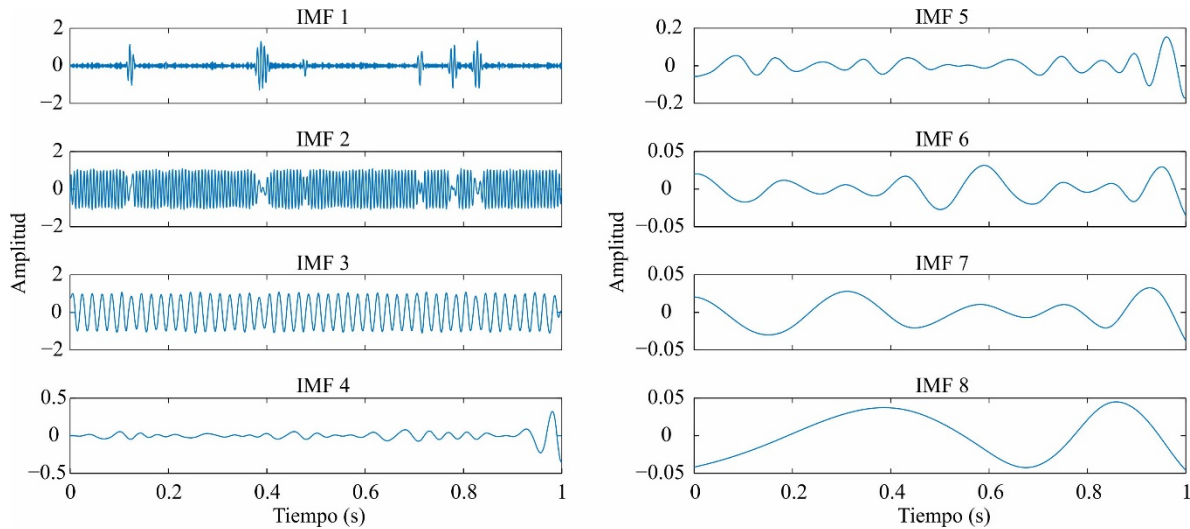


Figura 3.4 IMFs obtenidas de la señal ilustrada en la Figura 3.3 (b)

Como se observa en la figura, se puede apreciar que la IMF 1 contiene las oscilaciones de alta frecuencia, que para este trabajo es el ruido blanco añadido, por lo que se puede descartar su uso posterior. Las dos frecuencias que contiene la señal (150 y 200 Hz) se muestran en las IMF 2 y 3, indicando que, para las señales a procesar, pueden utilizarse las IMFs posteriores a la IMF 1. Finalmente, se observa que las últimas IMFs (6 a 8) muestran oscilaciones de muy baja frecuencia, por lo que pueden también descartarse para el posterior análisis con los indicadores anteriormente descritos. Los resultados obtenidos muestran la capacidad que tiene la EMD de trabajar con señales que están contenidas en una señal ruidosa.

Una vez obtenidas las IMFs, es necesario calcular las características no lineales de cada IMF, para lo cual se utiliza tanto las entropías (Shannon y de Permutación), así como los fractales (Katz, Higuchi y Dimensión de Cajas) y determinar cuántos indicadores o características son los que aportan la mayor información posible para proponer el clasificador. Para este propósito, se obtiene el valor P de cada indicador entre los estados sanos y con alteración en el ritmo cardiaco y se seleccionan aquellos que tienen el valor de P más cercano a 0, para con ellos construir el clasificador que permita cumplir con el objetivo de esta tesis: el detectar un evento de MSC hasta 25 minutos antes de que éste suceda.

CAPÍTULO 4

Resultados obtenidos

4. RESULTADOS OBTENIDOS

En esta sección se presentan y discuten los resultados que se obtuvieron empleando la metodología descrita en el capítulo previo.

4.1 Resultados

Siguiendo los pasos de la metodología propuesta, los intervalos de un minuto de las señales sanas y las que contienen un episodio de muerte súbita cardiaca se descomponen utilizando el método EMD, donde se obtienen seis IMF's; estas son analizadas utilizando los indicadores de los fractales de Katz (FK), Higuchi (FH), Dimensión de Cajas (FDC), entropía de Shannon (ES), entropía de permutación (EP). Para ejemplificar las señales analizadas, la Figura 4.1 muestra las IMFs de una señal de un paciente sano y un segmento de un minuto antes de la MSC. Se muestran únicamente las primeras 6 ya que las restantes son oscilaciones de muy baja frecuencia que no aportan información relevante para este trabajo. De esta figura, se puede concluir que en las señales las diferencias visuales que se observan no son producidas por la condición cardíaca (Ebrahimzadeh et al., 2014), si no que están asociadas al género, edad o la condición física del paciente, entre otras causas.

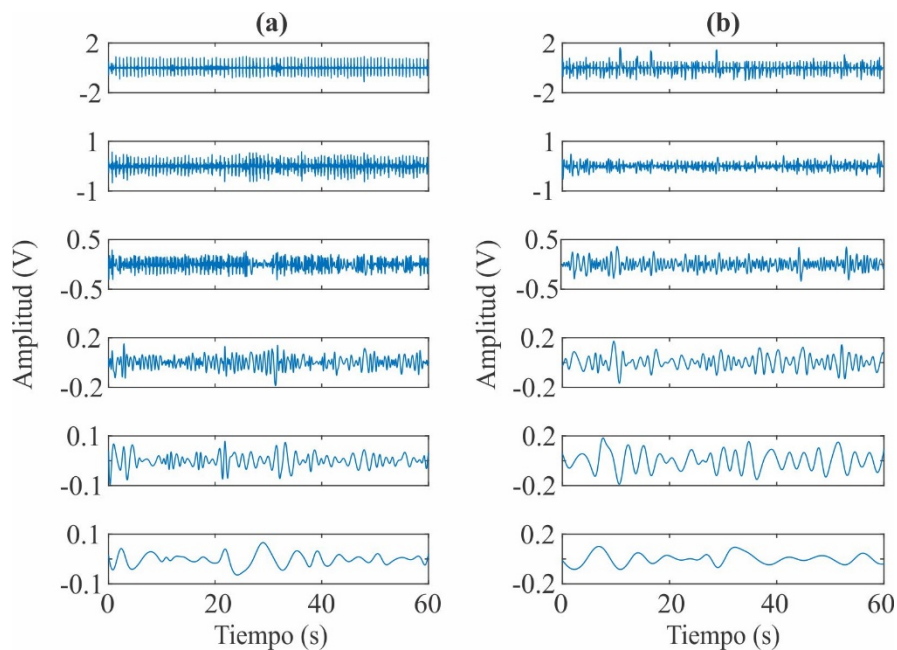


Figura 4.1 IMFs de un paciente (a) sano y (b) con MSC

Una vez obtenidas las IMFs, los 5 indicadores mencionados anteriormente se calculan para cada uno de éstos. Los resultados son una estimación de 30 indicadores para cada paciente y cada condición. En otras palabras, 480 valores son calculados para cada intervalo de un minuto. Todos los valores son analizados utilizando el método ANOVA de una vía para determinar cuál de estos indicadores es la característica más discriminante. Las Figuras 4.2 a 4.7 muestran de manera gráfica el valor para cada IMF, es decir la Figura 4.1 muestra el valor de P para los 5 indicadores (FK, FH, FDC, ES y EP) de la IMF 1 y así sucesivamente. Se observa en la figuras que las IMF 1 y IMF 2 tienen valores P grandes, por lo que su uso se puede descartar. Las IMFs restantes (3, 4 y 5) pueden emplearse, pues los valores de P son pequeños. A partir de un análisis cuidadoso de estos valores, se obtiene que el valor EP para la IMF 5 y el valor de HI para la IMF 3 son los que nos dan la mayor contribución estadística, ya que se obtiene un valor $P (< 1 \times 10^{-4})$ bajo para cada indicador. Por consiguiente, se puede afirmar que ambos valores tienen la información necesaria para distinguir una persona con una señal de corazón normal y una que sufrirá un episodio de muerte súbita cardíaca sin considerar su edad o condición física hasta 25 minutos antes del evento.

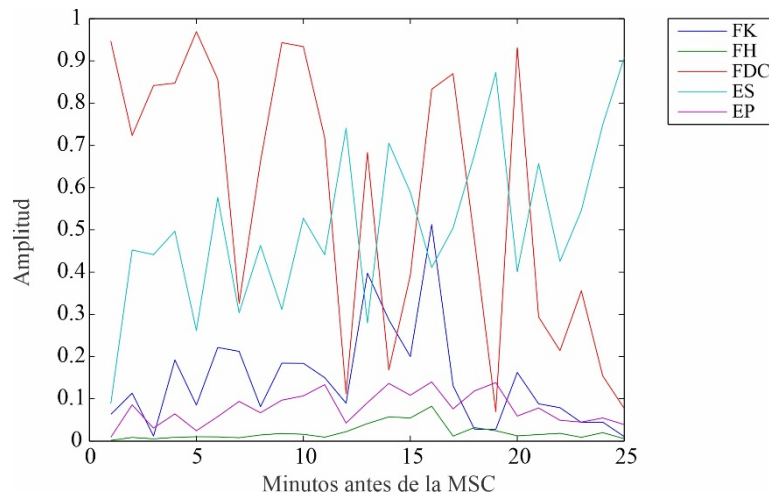


Figura 4.2 Valor de P para la IMF 1 de los 5 indicadores.




Figura 4.3 Valor de P para la IMF 2 de los 5 indicadores.

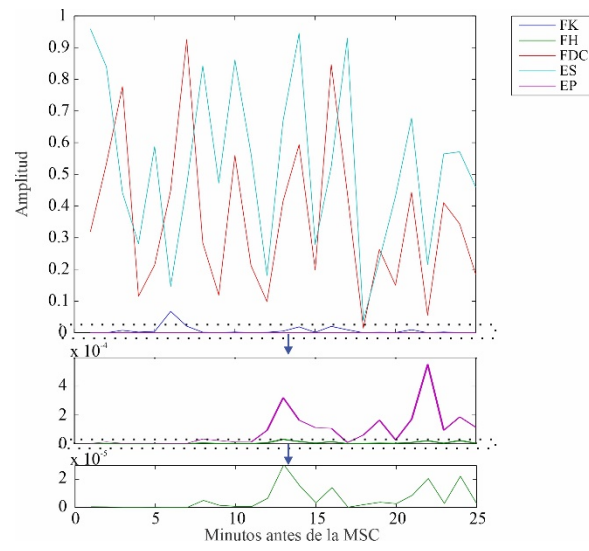


Figura 4.4 Valor de P para la IMF 3 de los 5 indicadores.




Figura 4.5 Valor de P para la IMF 4 de los 5 indicadores.




Figura 4.6 Valor de P para la IMF 5 de los 5 indicadores.




Figura 4.7 Valor de P para la IMF 6 de los 5 indicadores.

Las Figuras 4.8 (a) y 4.8 (b) muestran la distribución del valor EP usando la IMF 5 y la distribución del valor FH usando la IMF 3, respectivamente. Los pacientes con señales normales del corazón se denotan con la letra S, mientras que los cuadros restantes muestran los valores de EP y FH, respectivamente, en intervalos de 1 minuto hasta 25 minutos antes del evento MSC. De estas figuras, se observa que hay una diferencia evidente entre los valores del grupo S y el grupo con un alto riesgo de sufrir un episodio de MSC. En particular, hay algunos valores que están lejos de la zona central, denotados con un símbolo “+”, que la mayoría de las veces se encuentran fuera de la zona para pacientes normales. No obstante, estos valores también son considerados para generar el conjunto de datos de entrenamiento del clasificador, puesto que son valores que pueden ser calculados, por lo que el clasificador debe poder interpretar. Es importante mencionar que las señales ECG pueden ser afectadas por factores como la edad, la posición del cuerpo al medirlas, el estado emocional del paciente, entre otros (Amezquita-Sanchez et al., 2018). Esto permite tener distintos ritmos cardíacos, así se producen y se miden diferentes formas de onda. Sin embargo, la combinación de los dos indicadores permite generar la información suficiente para generar un clasificador preciso.




Figura 4.8 Distribución ANOVA de valores para a) EP de la IMF 5 y b) FH de la IMF 3.

La Tabla 4.1 muestra el resumen del promedio (μ), desviación estándar (σ) y el valor p para los dos indicadores, desde el minuto 1 hasta el minuto 25, antes de que el episodio de MSC suceda, en intervalos de 1 minuto; donde se puede observar que el valor p es menor que 0.00001 para todos los intervalos. Después de seleccionar ambos valores (EP de la IMF 5 y FH de la IMF 3), una red neuronal artificial es diseñada como clasificador. Para ello, 8 pacientes de cada clase (50% de la información disponible), son seleccionados aleatoriamente, donde los valores máximos y mínimos de cada intervalo se obtiene para generar 400 valores aleatorios dentro de los límites. Este procedimiento permite asegurar la diversidad necesaria para capturar todos los valores posibles que indiquen la existencia de un evento de muerte súbita cardíaca. El número de neuronas empleado en la capa oculta es de 30 y el algoritmo Leverberg-Marquardt se utiliza para determinar los valores de pesos y bias. Por último, el clasificador se valida usando el 50% de información restante, donde los pacientes se seleccionan al azar.

Tabla 4.1. Valores de promedio, desviación estándar y valor p de los dos indicadores (EP y FH) para los 25 minutos de ambas señales ECG.

SANO		MSC		
		Minuto	$\mu \pm \sigma$	Valor P
FH	1.4061 \pm 0.0892	25	FH 1.1875 \pm 0.1077	4.71E-07
	EP 1.0793 \pm 0.0143		EP 1.0505 \pm 0.0126	1.25E-06
		24	FH 1.2055 \pm 0.1231	3.77E-07
			EP 1.0556 \pm 0.0138	4.42E-05
		23	FH 1.2014 \pm 0.1187	1.71E-07

		EP	1.0533 ± 0.0128	7.37E-06
		FH	1.2050 ± 0.1082	2.16E-07
	22	EP	1.0528 ± 0.0113	2.28E-06
		FH	1.1948 ± 0.1051	1.02E-06
	21	EP	1.0517 ± 0.0110	1.02E-06
		FH	1.1885 ± 0.1038	2.31E-08
	20	EP	1.0539 ± 0.0119	6.28E-06
		FH	1.1829 ± 0.0874	8.24E-08
	19	EP	1.0498 ± 0.0114	4.11E-07
		FH	1.1943 ± 0.1167	5.04E-06
	18	EP	1.0507 ± 0.0191	4.19E-05
		FH	1.1915 ± 0.1065	1.50E-06
	17	EP	1.0507 ± 0.0163	1.09E-05
		FH	1.1902 ± 0.1173	8.04E-07
	16	EP	1.0521 ± 0.0166	2.51E-05
		FH	1.1925 ± 0.1270	6.35E-07
	15	EP	1.0527 ± 0.0136	7.55E-06
		FH	1.2034 ± 0.1191	6.55E-06
	14	EP	1.0511 ± 0.0151	7.00E-06
		FH	1.2160 ± 0.1026	3.07E-05
	13	EP	1.0550 ± 0.0147	4.98E-05
		FH	1.2165 ± 0.1071	1.54E-05
	12	EP	1.0544 ± 0.0146	3.42E-05
		FH	1.2086 ± 0.1126	3.37E-06
	11	EP	1.0516 ± 0.0165	1.92E-05
		FH	1.2160 ± 0.1241	1.42E-05
	10	EP	1.0531 ± 0.0172	5.66E-05
		FH	1.1960 ± 0.0905	1.85E-07
	9	EP	1.0527 ± 0.0125	4.16E-06
		FH	1.2052 ± 0.0742	2.01E-06
	8	EP	1.0549 ± 0.0180	8.71E-05
		FH	1.2114 ± 0.0923	3.75E-06
	7	EP	1.0557 ± 0.0164	8.92E-05
		FH	1.2039 ± 0.0811	2.66E-06
	6	EP	1.0524 ± 0.0156	1.88E-05
		FH	1.2076 ± 0.0819	8.69E-06
	5	EP	1.0541 ± 0.0184	1.55E-04
		FH	1.2144 ± 0.0861	2.07E-05
	4	EP	1.0547 ± 0.0172	1.21E-04
		FH	1.2052 ± 0.1038	2.85E-06
	3	EP	1.0546 ± 0.0184	9.37E-05
		FH	1.2192 ± 0.1194	2.23E-05
	2	EP	1.0553 ± 0.0197	9.24 E-04
		FH	1.2019 ± 0.1108	2.87E-06
	1	EP	1.0530 ± 0.0168	4.29E-05

La Tabla 4.2 muestra los resultados obtenidos por la red neuronal para la detección de la MSC, donde se observa que la metodología propuesta alcanza una buena exactitud, en promedio un 94%, hasta los 25 minutos antes de que ocurra la MSC. Estos resultados demuestran que la metodología alcanza intervalos de

detección suficientes para permitir que las personas en riesgo tomen acciones pertinentes (como un tratamiento médico) y poder llegar a un centro hospitalario para obtener la ayuda necesaria. De esta manera, se puede incrementar la tasa de sobrevivencia de esta enfermedad. Además, se sabe que las señales electrocardiográficas tienen un comportamiento no lineal (Ebrahimzadeh et al., 2014; Murukesan et al., 2014; Fujita et al., 2016; Finocchiaro et al., 2017; Amezquita-Sanchez et al., 2018). En este sentido, los indicadores utilizados en este trabajo pueden trabajar de buena manera con señales no lineales (Amezquita-Sanchez et al., 2016), el cual en conjunto con un clasificador basado en redes neuronales permiten desarrollar una metodología que indique la posibilidad de sufrir un evento de MSC hasta 25 minutos antes de que suceda.

Tabla 4.2. Muestra la exactitud, obtenida con la metodología propuesta por minuto.

MINUTO	EXACTITUD
1	90%
2	100%
3	90%
4	100%
5	90%
6	100%
7	90%
8	100%
9	100%
10	90%
11	90%
12	90%
13	100%
14	90%
15	100%
16	90%
17	90%
18	100%
19	90%
20	100%
21	100%

22	90%
23	90%
24	100%
25	100%
PROMEDIO	94%

4.2 Discusión de Resultados

Los resultados obtenidos muestran que la metodología propuesta permite predecir o anticipar un infarto con una exactitud del 94%, el cual es un periodo largo de tiempo, relativamente, ya que con este intervalo de tiempo es posible llegar a un hospital para recibir la atención médica necesaria. Como mencionan Amezcuita-Sanchez et al. (2018), la predicción de la MSC es un reto debido a que las señales ECG tienen cambios sutiles que los indicadores de diagnóstico pueden detectar; sin embargo, se conoce que las señales ECG tienen un comportamiento no lineal (Ebrahimzadeh et al., 2014; Murukesan et al., 2014; Fujita et al., 2016; Finocchiaro et al., 2017; Amezcuita-Sanchez et al., 2018). En este sentido, los indicadores utilizados en este trabajo pueden trabajar apropiadamente con señales no lineales (Amezcuita-Sanchez et al., 2016) los cuales en conjunto con un clasificador basado en redes neuronales permite desarrollar una metodología capaz de predecir de manera anticipada un evento de muerte súbita cardíaca.

Una comparación entre los artículos más recientes sobre el tema utilizando la misma base de datos se muestra en la Tabla 4.3. La cual incluye la cantidad de minutos previos al ataque en el cual se puede detectar la muerte súbita cardíaca, la exactitud obtenida, y una breve descripción de la metodología utilizada para dichos resultados; se observa que las metodologías que tienen una alta exactitud utilizan algoritmos como diferentes entropías, exponente de Hurst, dimensión de correlación, entre otros, que pueden procesar señales no lineales; sin embargo, se requiere el uso de por lo menos 3 indicadores para realizar una predicción, el cual, en consecuencia, incrementa el tiempo requerido para arrojar un resultado. En contraste, la metodología propuesta utiliza únicamente dos indicadores, haciendo que se requiera de un menor tiempo computacional. Otro aspecto que debe

mencionarse de la metodología propuesta es el intervalo de predicción del evento de MSC; en este sentido, este trabajo permite detectar hasta 25 minutos antes de que suceda, lo que es una mejora importante a los trabajos reportados anteriormente.

Tabla 4.3. Resumen de trabajos anteriores que utilizan la misma base de datos.

Autores (año)	Tipo de señales	Metodología propuesta	Tiempo de predicción (exactitud)
Shen et al. (2007)	ECG	<ul style="list-style-type: none"> Se utilizan tres características para predecir la MSC: (1) Promedio de la variabilidad del ritmo cardíaco, (2) la razón de baja frecuencia/ alta frecuencia, y (3) Muy baja frecuencia. El clasificador utilizado es una red neuronal artificial. 	2 minutos (67.44 %)
Ebrahimzadeh y Pooyan (2011)	HRV	<ul style="list-style-type: none"> Se realizan tres análisis, el primero usa características clásicas como el dominio del tiempo y dominio de frecuencia, el segundo es un análisis de dominio tiempo-frecuencia, en el cual 10 características se extraen (energía máxima y mínima, la diferencia de las energías en cada ventana de tiempo, desviación estándar de las energías, la energía total de la señal con muy baja frecuencia, baja y alta frecuencia, el promedio de la energía en la señal de muy baja frecuencia, baja y alta frecuencia.) El último es un análisis no lineal, en el cual dos parámetros de los intervalos RR son extraídos con el método Poincaré y el análisis de fluctuación desmedida. El método del vecino más cercano es utilizado como clasificador en este trabajo. 	4 minutos (83.96 %)
Ebrahimzadeh et al. (2014)	HRV	<ul style="list-style-type: none"> Se extraen 5 características (promedio y desviación estándar de los intervalos NN, la raíz cuadrada de la suma de los cuadrados de las diferencias de los intervalos adyacentes de los intervalos NN, así como la desviación estándar, la proporción derivada de la división del número de diferencia de los intervalos NN mayores a 50 MS por el número total de estos intervalos; igualmente, se extrajeron cuatro características en el dominio de la frecuencia, muy baja frecuencia, baja frecuencia, alta frecuencia y la razón de la baja entre la alta frecuencia. El principal componente de análisis es utilizado para seleccionar las características más relevantes. El clasificador corre a cargo de un perceptrón multicapa. 	1 minutos (99.16 %)
Acharya et al. (2015)	ECG	<ul style="list-style-type: none"> 18 características no lineales son extraídas de la señal, entre las que están, la dimensión fractal, exponente de Hurst, entropía aproximada, entropía por muestras, análisis de fluctuación desmedida, dimensión de correlación. Los clasificadores para este trabajo son, el árbol de decisión, vector de soporte de máquina, y el vecino más cercano. 	4 minutos (92.11 %)
Fujita et al. (2016)	HRV	<ul style="list-style-type: none"> Las señales HRV son extraídas utilizando el algoritmo Pan-Tompkins. A las señales se les quita ruido utilizado el esquema basado en la transformada wavelet discreta. Para cada intervalo, se calculan 12 valores de la entropía difusa, entropía de Renyi, los parámetros de Hjorth entropía de Tsallis y la energía obtenida de los tres niveles de energía. 	4 minutos (94.7 %)

Amezquita-Sánchez et al. (2018)	ECG	<ul style="list-style-type: none"> • Se utilizan señales de 1 minuto que son descompuestas utilizando la transformada wavelet packet para generar bandas de frecuencias uniformes. • Se calcula el índice de homogeneidad como una característica. • La clasificación se realiza con una red neuronal probabilística mejorada. 	20 minutos (95.8 %)
Presente trabajo	ECG	<ul style="list-style-type: none"> • Se utilizada la EMD para obtener componentes de la señal, IMF's. • Se calculan los valores del fractal de Higuchi y de entropía de permutación, como indicadores. • Se utiliza el perceptrón multicapa como clasificador. 	25 minutos (94 %)

CAPÍTULO 5

Conclusiones y prospectivas

5. CONCLUSIONES Y PROSPECTIVAS

5.1 Conclusiones

La detección de la muerte súbita cardíaca es una tarea difícil ya que la señal ECG tienen cambios sutiles; además, es indetectable en personas que están en riesgo de padecer un evento de este tipo. En consecuencia, entre más temprana sea la detección, mejor será la probabilidad de sobrevivir a esta afección cardíaca.

Este trabajo propone una nueva metodología que combina la EMD y los valores del fractal de Higuchi y de la entropía de permutación, utilizando señales ECG de la base de datos MIT/BIH-SCDH y MIT/BIH-NSR, para predecir un evento de muerte súbita cardíaca 25 minutos antes de que este ocurra. El trabajo obtiene señales de 1 minuto, utilizando la EMD, las cuales son procesadas con algoritmos del fractal de Higuchi y de la entropía de permutación, para obtener las características que permiten predecir la MSC. Los resultados muestran que en la IMF 3 y en la IMF 5 se puede detectar la MSC; los valores de ANOVA de una vía, muestran que estos tienen la mayor relevancia, donde el clasificador neuronal se utiliza, y se obtiene un 94% de exactitud. Sin embargo, la predicción temprana de un evento de MSC se mejora en un 25%, lo que amplía el tiempo para poder recibir tratamiento médico adecuado, incrementando la posibilidad de sobrevivir a la muerte súbita sin tener consecuencias físicas.

5.2 Prospectivas

Como trabajo futuro, queda el hacer un análisis con un mayor número de pacientes para revisar la consistencia de los valores obtenidos en una base de datos más grande. Además, intervalos más pequeños de las señales y un mayor tiempo de predicción pueden llevar a mejorar las posibilidades de mitigar los efectos médicos que un episodio de MSC puede traer.

Por otra parte, el poder implementar este sistema de detección en un aparato portable ayudará a disminuir la tasa de mortalidad por la muerte súbita cardíaca y se podrá lograr el objetivo mayor de esta investigación, salvar pacientes.

6. REFERENCIAS

Acharya, U.R., Fujita, H., Sudarshan, V.K., Ghista, D.N., Liem, W.J.E., KoH, J.E. (2015) *Automated prediction of sudden cardiac death risk using Kolmogorov Complexity and Recurrence Quantification Analysis features extracted from HRV signals*. In IEEE International Conference on Systems, Man, and Cybernetics, Kowloon, pp. 1110-1115.

Acharya, U.R., Joseph, P.K., Kannathal, N., Lim, C.M., Suri J.S. (2006) *Heart rate variability: a review*. Medical and Biological Engineering and Computing, **44**, 1031-51, 2006.

Adabag, A.S., Luepker, R.V., Roger V.L., y Gersh, B.J. (2010) *Sudden Cardiac Death: epidemiologic and risk factors*, *National Reviews Cardiology*, **7**, pp. 216-225.

Aguilera, A., Fraga, J., y Asensio, L. (2012) *Análisis de la inclusión de la policía en la respuesta de emergencias al paro cardiorrespiratorio extra-hospitalario*. *Salud Pública Mexicana*, **54**, pp. 60-7.

Agatonovic-Kustrin, S., & Beresford, R. (2000). *Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research*. *Journal of Pharmaceutical and Biomedical Analysis*, 22(5), 717–727. doi:10.1016/s0731-7085(99)00272-1

Amezquita-Sanchez, J., Adeli, A., Adeli, H. (2016) *A new methodology for automated diagnosis of mild cognitive impairment (MCI) using magnetoencephalography (MEG)*. *Behavioural Brain Research*, 305, 174-180.

Amezquita-Sanchez, J., Valtierra-Rodriguez, M., Adeli, H., Pérez-Ramírez, C. (2018) *A Novel Wavelet Transform-Homogeneity Model for Sudden Cardiac Death Prediction Using ECG Signals*. *Journal of Medical Systems*, 42, 176.

Asensio, E., Narváez, R., Dorantes, J., et al. (2005) *Conceptos actuales sobre la muerte súbita*. *Gaceta Medica de México*. **141**, pp. 89-98.

Baez-López, D. (2010). MATLAB® with Applications to Engineering, Physics and Finance. Florida: CRC Press. Pp. 1-2

Bakieva, M., Gonzalez-Such, J., Jornet, J. (s.f) *SSPS: ANOVA de un factor*. InnovaMIDE, 1-7.

Bandt, C., & Pompe, B. (2002). *Permutation entropy: A natural complexity measure for time series*. Physical Review Letters, 88, 174102

Bayés de Luna, A. *Clinical arrhythmology* (2011). Wiley-Blackwell, John Wiley and Sons, Ltd., Publication.

Carrasco, A. (2019) *Desarrollo de un sistema de adquisición y procesamiento basado en la transformada de Fourier y LabVIEW para señales eléctricas cardíacas* (Tesis de licenciatura). Universidad Autónoma de Querétaro, Querétaro.

Cruz, H. (2018) *Metodología basada en la Descomposición Empírica de Modos Completa y Fractales para la Clasificación de Imaginación Motora usando Señales Electroencefalográficas* (Tesis de licenciatura). Universidad Autónoma de Querétaro, Querétaro.

Córdova, F. (2013) *Desarrollo de un sistema para la evaluación de la actividad muscular mediante electrodos de superficie*. (Tesis de licenciatura) Pontificia Universidad Católica del Perú, Lima, Perú.

Ebrahimzadeh, E., Foroutan, A., Shams, M., Baradaran, R., Rajabion, L., Joulani, M., Fayaz, F. (2019) An optimal strategy for prediction of sudden cardiac death through a pioneering feature-selection approach from HRV signal. *Computer Methods and Programs in Biomedicine*, 169, 19-36.

Ebrahimzadeh, E., Pooyan, M. (2011) *Early detection of sudden cardiac death by using classical linear techniques and time-frequency methods on electrocardiogram signals*. *Biomedical Science and Engineering*, 11, 699–706.

Ebrahimzadeh, E., Pooyan, M., and Bijar, A., (2014) *A novel approach to predict sudden cardiac death (SCD) using nonlinear and time-frequency analyses from HRV signals*. PloS one 9(2): e81896.

Engelstein, E.D., Zipes, D.P. *Sudden Cardiac Death*, in: R.W. Alexander, R.C. Schlant, V. Fuster (Eds.), *The Heart, Arteries and Veins*, McGraw-Hill, New York, NY, 1998, pp. 1081–1112.

Fernandez-Chimeno, M., Quilez, M., Silva, F. (2006) *Understanding electrosurgical unit perturbations in order to address hospital operating room electromagnetic compatibility*. IEEE Trans. Biomed. Eng. 53(6), 1205–1207.

Fishman G, Chung S, DiMarco J, et al. (2010) *Sudden cardiac death prediction and prevention: Report from a National Heart, Lung, and Blood Institute and Heart Rhythm Society Workshop*. Circulation. **122**, pp. 2335-48. DOI: 10.1161/CIRCULATIONAHA.110.976092

Gacek, A., Pedrycz, W. (2012), *ECG Signal Processing, Classification and Interpretation: A Comprehensive Framework of Computational Intelligence*. Londres, Inglaterra: Springer.

García, J.C. (2009). Capítulo 3: Fisiología cardíaca de libro de la salud cardiovascular del hospital Clínico San Carlos y Fundación BBVA, *Madrid*, 1st ed. Bilbao: Nerea S.A, pp.41-47.

García, J.G. (2011) *Sistema de reconocimiento de voz usando perceptron multicapa y coeficientes Cepstrales de Mel. (tesis de maestría)*. Universidad Autónoma de Querétaro, Querétaro.

Gardner, M. & Dorling, S. (1998). *Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences*. Atmospheric Environment, 32(14-15), 2627–2636. doi:10.1016/s1352-2310(97)00447-0

González-Hermosillo J.A., Marquez, M.F., Cárdenas, M. (2004) *Risk stratification for sudden cardiac death*. Harrison's Online: Part 8, Reviews, Chapter 243. USA: McGraw-Hill Co.

Hernández, V.H. (2015) Desarrollo de un sistema para la adquisición de señales biométricas en roedores. (tesis de licenciatura). Universidad Autónoma de Querétaro, Querétaro.

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

Huang, N., Shen, Z., Long, S., Wu, M., Shih, H., Zheng, Q., Liu, H. *The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis*. Proc. Royal Society London A: Math. Phys. Eng. Sciences, 454(1971) (1998), 903-995, doi: 10.1098/rspa.1998.0193

James, E., Anchin, J., & Weiss, D. (2008). *Nonlinear analysis of the heartbeats in public patient ECGs using an automated PD2i algorithm for risk stratification of arrhythmic death*. Ther Clin Risk Manag, 4, 549-557.

Katz, M. J. (1988). *Fractals and the analysis of waveforms*. Comp. Biol. Med., 18 (3), 145-156, doi; 10.1016/0010-4825(88)90041-8

Kong, M.H., Peterson, E.D., Fonarow, G.C., Sanders, G.D., Yancy, C.W., Russo, A.M., Curtis, A.B., Sears, S.F. Jr, Thomas, K.L., Campbell, S., Carlson, M.D., Chiames, C., Cook, N.L., Hayes, D.L., LaRue, M., Hernandez, A.F., Lyons, E.L., Al-Khatib, S.M. (2010) *Addressing disparities in sudden cardiac arrest care and the underutilization of effective therapies*. American Heart Journal.pp.160:605-18, e1. doi: 10.1016/j.ahj.2010.07.011.

Link, M.S., Atkins D.L., Passmam, R.S., Halperin, H.R., Samson, R.A., White, R.D., Cudnik, M.T., Berg, M.D., Kudenchuk, P.J., Kerber, R.E. (2011) *Automated*

external defibrillators, defibrillation, cardioversion, and pacing 2010 American Heart Association Guidelines for Cardiopulmonary Resuscitation and Emergency Cardiovascular Care. Circulation. 123(6):e235- DOI: 10.1161/CIRCULATIONAHA.110.970954

Loiza, J.O. (2015) *Electrocardiograma y su relación con la arteria culpable demostrada mediante coronografía de pacientes con síndrome isquémico coronario agudo ingresados al área de urgencias del Hospital General de Querétaro del 1ro de enero del 2010 al 31 de diciembre de 2011 (tesis de especialidad)*. Universidad Autónoma de Querétaro, Querétaro.

Lopez-Ramirez, M., Ledesma-Carrillo, L., Cabal-Yeppez, E., Rodriguez-Donate, C., Miranda-Vidales, H., & Garcia-Perez, A. (2016). *EMD-Based Feature Extraction for Power Quality Disturbance Classification Using Moments*. Energies, 9(7), 565. doi:10.3390/en9070565

Manis, G., Nikilopoulos, S., Arsenos, P., Gatzoulis, K., Dilaveris, P., Stefanadis, C. (2013). *Risk stratification for arrhythmic sudden cardiac death in heart failure patients using machine learning techniques*. Computing in cardiology, 40, 141-144.

Mejia-Barron, A., de Santiago-Perez, J.J., Granados-Lieberman, D., Amezcua-Sanchez, J.P., Valtierra-Rodriguez, M. (2019). *Shannon Entropy Index and a Fuzzy Logic System for the Assessment of Stator Winding Short-Circuit Faults in Induction Motors*. Electronics, 8, 90, doi: 10.3390/electronics8010090

Myerburg, R.J., Reddy, V., Castellanos, A. (2009) *Indications for implantable 597 cardioverter defibrillators based on evidence and judgment*, Journal of the American College Cardiology. 54 747–763. doi: 10.1016/j.jacc.2009.03.078

Neuman MR. (2009). Biopotential electrodes, JW Webster (ed.), *Medical Instrumentation: Application and Design*. John Wiley and Sons, 4th ed. 189-209.

Nicolaou, N., & Georgiou, J. (2012). *Detection of epileptic electroencephalogram based on Permutation Entropy and Support Vector Machines*. *Expert Systems with Applications*, 39(1), 202–209. doi:10.1016/j.eswa.2011.07.008

OMS (2018). *Enfermedades cardiovasculares*. Sitio web: <http://www.who.int/mediacentre/factsheets/fs317/es/> Accesado el día 19 de febrero de 2018.

Pagidipati, N. J., & Gaziano, T. A. (2013). Estimating deaths from cardiovascular disease: a review of global methodologies of mortality measurement. *Circulation*, 127(6), 749-756.

Rajendra-Archarya, U., Sudarshan, V., Noshir-Ghista, D. (2015) *Automated prediction of sudden cardiac death risk*. IEEE international conference on systems, man, and cybernetics, at Hong Kong. DOI: 10.1109/SMC.2015.199

Rea, T., Page, R.L. (2010) *Community approaches to improve resuscitation after out-of- 624 hospital cardiac arrest*, *Circulation* 121, pp.1134–1140.

Sánchez Pérez, A. V. (2019) *Metodología basada en la Transformada Wavelet y Fractales para la detección anticipada de eventos epilépticos*. Universidad Autónoma de Querétaro, Querétaro.

Shannon, C. (1948) *A mathematical theory of communication*. *Bell Sys. Tech. J.* 27(3), 543 379–423, doi: 10.1145/584091.584093

Saavedra, V. (2008) *Análisis comparativo de métodos para el estudio de banda ancha del electroencefalograma (tesis doctoral)*. Universidad Autónoma de Querétaro, Querétaro.

Shen, T.W., Shen,H.P., Lin, C., Ou, Y. (2007)*Detection and prediction of Sudden Cardiac Death (SCD) for personal healthcare*. 29th Annual International Conference of the IEEE, Buenos Aires, 22-26 August, 2575-2578.

Stecke, E.C., Reinier, K., Marijon, E., Narayanan, K., Teodorescu, C., Uyevanado, A., Gunson, K., Jul, J., Chugh, S.S. (2014) *Public health burden of sudden cardiac death in the United States*. *Circulation Arrhythmia Electrophysiol.* Pp.7:212-7. Doi: 10.1161/CIRCEP.113.001034

Swapna, G., Ghista, D.N, Martis, R.J., Ang, A.P.C, Sree, S.V. (2012) *ECG signal generation and heart rate variability signal extraction: signal processing, features detection, and their correlation with cardiac diseases*. *J. Mech. Med. Biol.* 2-6. DOI: 10.1142/S021951941240012X.

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

Vignolo Barchiesi Juan. (2008). *Introducción al procesamiento digital de señales*. Chile. Ediciones Universitarias de Valparaíso, 19-20.

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

Zanin, M., Zunino, L., Rosso, O. A., & Papo, D. (2012). *Permutation Entropy and Its Main Biomedical and Econophysics Applications: A Review*. *Entropy*, 14(8), 1553–1577. doi:10.3390/e14081553

Zipes, D.P., Camm, A.J., Borggrefe, M., Buxton, A.E., Chaitman, B., Former, et al (2006). *ACC/AHA/ESC 2006 guidelines for management of patients with 654 ventricular arrhythmias and the prevention of Sudden Cardiac Death*. *Circulation* 2006, 114, pp. e385–e484.