



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Ingeniería Biomédica

Desarrollo de una metodología basada en la teoría del caos para el diagnóstico anticipado de infartos a partir de ECG

TESIS

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

Presenta:

Antonio Bazaldúa Camacho

Dirigida por:

Dr. Juan Pablo Amézquita Sánchez

Dr. Carlos Andrés Pérez Ramírez

Querétaro, Qro, Octubre del 2019



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Ingeniería Biomédica



“Desarrollo de una metodología basada en la teoría del caos para el diagnóstico anticipado de infartos a partir de ECG”

Tesis

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

Presenta:

Antonio Bazaldúa Camacho

Dirigido por:

Dr. Juan Pablo Amézquita Sánchez

Dr. Carlos Andrés Pérez Ramírez

Dr. Juan Pablo Amézquita Sánchez
Presidente

Dr. Carlos Andrés Pérez Ramírez
Secretario

Dra. Vanessa Vallejo Becerra
Vocal

Dra. Georgina del Carmen Mota Valtierra
Suplente

Firma

Firma

Firma

GEORGINA MOTA V
Firma

Centro Universitario
Querétaro, Qro.
Octubre 2019

RESUMEN

Los problemas cardiovasculares y enfermedades crónicas derivadas de la mala alimentación, sedentarismo y obesidad son la principal causa de muerte en México. Más del 50% de la población del país padece alguna enfermedad relacionada a las ya mencionado, Sin embargo, de todas estas patologías los problemas y enfermedades cardiovasculares son la principal causa de muerte, sobre todo los infartos de miocardio. Un infarto de miocardio o ataque al corazón como coloquialmente se conoce es la destrucción de parte de la capa muscular del corazón por falta de oxígeno, por lo común los infartos de miocardio suele ocurrir al formarse coágulos de sangre en alguna de las arterias coronarias (vasos sanguíneos que comunican al corazón), provocando el bloqueo flujo sanguíneo al corazón.

En países de primer mundo este padecimiento tiene todavía un alto índice de mortalidad, pero se han logrado disminuir las cifras gracias a sus programas de salud y de desarrollo tecnológico. Por esta razón, existe la necesidad del desarrollo de tecnología, diagnóstico y prevención de enfermedades cardiovasculares en México. Con base en esto, este trabajo de tesis busca el desarrollo de una metodología basada en el análisis de señales eléctricas del corazón que permita 14 minutos antes en que una persona pudiera sufrir un infarto. La metodología se realizará de acuerdo con la caracterización de una serie de señales de ECG de distintos pacientes tomados de la base de datos de PhysioNet, una base de datos de acceso libre, la cual comprende tanto pacientes sanos como pacientes que sufrieron y sobrevivieron a un infarto.

Palabras clave: Teoría del caos, señales ECG, prevención de infartos, fractalidad, redes neuronales, procesamiento de señales.

DEDICATORIA

Para mis padres Antonio Bazaldúa y Tomasa Camacho, así como a mi hermana Marisol que siempre estuvieron al pendiente de mí y sobre todo me brindaron todo su apoyo y comprensión en todo momento, que nunca dejaron de alentarme, de aconsejarme y sobre todo nunca dejaron de esforzarse y sacrificar cosas para lograr un paso más en mi vida. A ellos que no solo me dieron la oportunidad de ser un profesionista sino también me dieron una educación para ser mejor persona y merecen cada uno de mis logros.

Dirección General de Bibliotecas UNQ

AGRADECIMIENTOS

A mis padres Antonio Bazaldúa y Tomasa Camacho, que, gracias a ellos, su esfuerzo, apoyo y sacrificio hicieron posible la conclusión de esta etapa de mi vida.

A mi hermana y su esposo que durante tantos años me apoyaron brindándome un hogar y su apoyo incondicional.

Al Doctor Juan Pablo Amézquita que me tuvo demasiada paciencia para culminar este trabajo de tesis.

A cada uno de mis profesores a lo largo de la carrera y de la vida, pues cada uno de ellos apoyaron con su inculcación de conocimiento para poder culminar con cada uno de mis grados académicos.

A mi familia, primos, tíos, abuelos padres y hermanos, que siempre estuvieron pendiente de mí y me apoyaban en esos momentos difíciles donde quería desistir.

A la UAQ, mi alma mater que desde la preparatoria me ha brindado más de lo que podría regresarle y que casi se convirtió en un hogar, donde encontré otra familia y donde he obtenido demasiadas herramientas para la vida.

A mis amigos, compañero de la carrera, facultad y la universidad que me fui encontrando a lo largo de esta etapa pues algunos eran como parte de mi familia o yo de la de ellos.

ÍNDICE GENERAL

| | |
|---|------|
| RESUMEN | iii |
| DEDICATORIA | iv |
| AGRADECIMIENTOS | v |
| ÍNDICE GENERAL | vi |
| ÍNDICE DE FIGURAS | viii |
| ÍNDICE DE TABLAS | ix |
| | |
| 1. CAPÍTULO I | 10 |
| 1.1 Introducción | 10 |
| 1.2 Antecedentes | 11 |
| 1.3 Descripción del problema | 14 |
| 1.4 Justificación | 14 |
| 1.5 Hipótesis | 15 |
| 1.6 Objetivos | 15 |
| 1.6.1 Objetivos Generales | 15 |
| 1.6.2 Objetivos Particulares | 16 |
| 1.7 Planteamiento General | 16 |
| | |
| 2. CAPÍTULO II | 18 |
| 2.1 Revisión de la literatura | 18 |
| 2.2 Señales ECG | 18 |
| 2.2.1 Sensores para medición de señales ECG | 21 |
| 2.3 Procesamiento Digital de Señales | 22 |
| 2.3.1 MATLAB | 23 |
| 2.3.2 Dimensión Fractal | 24 |
| 2.3.2.1 Algoritmos de Katz. | 25 |
| 2.3.2.2 Algoritmos de Higuchi | 25 |
| 2.3.2.3 Dimensión de caja. | 27 |
| 2.3.2.4 Análisis de Varianza. | 27 |
| 2.3.2.5 Redes Neuronales Artificiales | 28 |

| | |
|--|----|
| 3. CAPÍTULO III | 30 |
| 3.1 Metodología..... | 30 |
| 3.2 Material..... | 32 |
| 3.3 Análisis de fractalidad de señales ECG..... | 33 |
| 4. CAPÍTULO IV | 35 |
| 4.1 Puesta de experimento..... | 35 |
| 4.2 Resultados | 36 |
| 4.3 Discusión de Resultados | 41 |
| 5. CAPÍTULO V | 43 |
| 5.1 Conclusiones..... | 43 |
| 5.2 Prospectiva..... | 44 |
| Referencias | 46 |
| Anexo A: Código de la lectura de las señales ECG y su análisis | 49 |
| Anexo B: Código entrenamiento y verificación de la red neuronal | 52 |

ÍNDICE DE FIGURAS

| | |
|--|----|
| Figura 1.1 Planteamiento general..... | 16 |
| Figura 2.1 Ubicación de los electrodo en la superficie del cuerpo humano para la medición de señales ECG | 19 |
| Figura 2.2 Ondas en el ritmo cardiaco | 20 |
| Figura 2.3 Diferentes tipos de electrodos | 21 |
| Figura 2.4 Ventana de inicio de Matlab..... | 24 |
| Figura 2.5 Estructura de Perceptrón Multicapa en une Red Neuronal..... | 28 |
| Figura 3.1 Diagrama de Bloques de la metodología propuesta..... | 30 |
| Figura 3.2. Segmentación de las señales ECG para un paciente (a) y (b) con infarto..... | 31 |
| Figura 3.3 Señales ECG generada artificialmente | 33 |
| Figura 4.1 (a) Señal ECG 1 antes del infarto y 1 minuto después del inicio y (b)señal de ECG con ritmo cardiaco sano..... | 35 |
| Figura 4.2 Distribución de los valores de FD obtenidos para (a) HFD-32, (b) HFD-64, (c) BD y (d) KFD para las señales de ECG de personas con ritmo cardiaco normal (N) y personas que sufrieron un infarto con intervalos de 1 minuto empezando desde el minuto 1 hasta el minuto 14 antes del infarto..... | 36 |

ÍNDICE DE TABLAS

| | |
|---|----|
| Tabla 3.1 Información Clínica de los participantes que sufrieron infartos | 31 |
| Tabla 3.2 Valores de los diferentes algoritmos de dimension fractal para la señal sinética..... | 33 |
| Tabla 4.1 Características más discriminantes del análisis de FD y ANOVA para las señales normales en los 14 intervalos de 1 minuto, 14 minutos antes del evento SCD..... | 37 |
| Tabla 4.2 Precisión de los resultados de la metodología propuesta minuto a minuto durante los 14 minutos anteriores al SCD..... | 39 |
| Tabla 4.3 Resumen de resultados con su metodología propuesta de trabajos recientes que han usado la misma base de datos..... | 41 |

Dirección General de Bibliotecas UAQ

CAPÍTULO I

1.1 Introducción

Actualmente, en México una gran parte de la población sufre de enfermedades crónicas, estas enfermedades son principalmente causadas por problemas relacionados con la obesidad. En México el 70% de la población padece de esta enfermedad, convirtiéndose en unas de las principales causas de muerte en el país. Sin embargo, las enfermedades cardiovasculares provocadas por problemas congénitos y principalmente por los efectos que provoca la diabetes y la obesidad, son la primera causa de muerte en el país con aproximadamente 128,731 defunciones al año según el (INEGI,2015) De estas enfermedades y padecimientos cardiovasculares, los infartos de miocardio provocan las mayores cantidades de muertes.

El infarto de miocardio, o también llamado ataque al corazón, ocurre cuando existe deficiencia de oxígeno provocando que la capa muscular del corazón colapse. Las principales causas de un infarto o ataque al corazón son debido a la existencia de coágulos sanguíneos, estos coágulos principalmente se localizan en una de las arterias que se comunica con el corazón directamente, la arteria coronaria. Estos coágulos provocan un bloqueo de flujo sanguíneo, lo que obstruye la llegada de sangre al corazón. Existen variadas circunstancias que provocan un bloque del flujo sanguíneo al corazón, en ocasiones el bloqueo puede presentarse debido a un espasmo o estrechamiento repentino de una arteria, coronaria principalmente.

Los primeros síntomas del inicio de un infarto al corazón se manifiestan con un dolor aplastante y agudo que puede abarcar desde el pecho hasta la parte inferior del pecho, mandíbula, orejas, miembros superiores. Las probabilidades de que un infarto ocurra son muy altas, cuando existe una disminución del del volumen de las arterias, principalmente provocado por la gran cantidad de depósitos grasos que se

pueden depositar en las paredes y a lo largo de las arterias. La probabilidad de que estos depósitos grasos se creen se atribuye a malos hábitos alimenticios, al consumir grandes cantidades de alimentos altos en grasas, también por el tabaquismo, la nula actividad física y la obesidad (NHS, 2008; IMFR, 2019).

En países de primer mundo este padecimiento tiene todavía un alto índice de mortalidad, pero se han logrado disminuir las cifras gracias a sus programas de salud y de desarrollo tecnológico (Excelsior, 2017). Por esta razón, se ha creado la necesidad del desarrollo de tecnología, diagnóstico y prevención de enfermedades cardiovasculares en México. Con base en lo antes mencionado, este trabajo de tesis busca el desarrollo de una metodología basada en el análisis de señales eléctricas (ECG) del corazón, para crear un sistema que permita anticipar el momento en que una persona pudiera sufrir un infarto, con el fin de que la persona pueda tomar previsiones o pueda ser enrollado en un tratamiento clínico.

La metodología se realizará de acuerdo con la caracterización de una serie de señales de ECG de distintos pacientes tomados de las bases de datos: "Normal Sinus Rhythm Database (NSR, 2018)" y "Sudden Cardiac Death Holter Database (SCD, 2018)", las cuales comprende tanto pacientes sanos y pacientes que sufrieron y sobrevivieron a un infarto, respectivamente, las cuales son de acceso libre.

1.2 Antecedentes

Los sistemas de diagnóstico y monitoreo del corazón permiten evaluar y supervisar la actividad eléctrica del corazón. La electrocardiografía es un método que permite registrar gráficamente las señales eléctricas del corazón, lo que ayuda a detectar alteraciones en el ritmo cardiaco. Con este método es posible analizar el comportamiento del corazón del paciente, y apoyar al médico profesional a emitir el diagnóstico correcto (Álvarez, 2010).

Existen múltiples trabajos e investigaciones acerca de temas relacionados con la obtención y análisis de señales del corazón y no solo eso, también muchas de estas investigaciones tienen el fin de crear metodologías que permitan disminuir

el número de personas muertas por haber sufrido de un infarto. Por ejemplo, en el plano internacional, Murugappan et al. (2015) realizaron un análisis estadístico de la señal ECG (media entre los picos RR, mediana entre los picos RR, desviación estándar entre los picos RR, la media del ritmo cardiaco, la desviación estándar del ritmo cardiaco) para el diagnóstico anticipado de infartos. Los resultados obtenidos muestran que la propuesta es capaz de estimar la posibilidad de un infarto hasta 4 minutos antes con una eficiencia del 93%. Por otro lado, Acharya et al. (2015) desarrollaron una metodología basada en la transformada wavelet para el diagnóstico anticipado de infartos. Los resultados obtenidos muestran que la metodología propuesta es capaz de detectar la posibilidad de un infarto hasta 4 minutos antes con una eficiencia del 92%. Continuando con la investigación de Acharya et al. (2015), Fujita et al. (2016) realizaron un estudio de diferentes métodos no lineales (energía, entropía difusa, entropía de Renyi, entropía de Tsallis) para el diagnóstico anticipado de infartos empleando variabilidad de la frecuencia cardiaca (HRV) de las señales ECG. La combinación de los métodos propuestos fue capaz de diagnosticar la posibilidad de un infarto hasta 4 minutos antes con una eficiencia del 94%. Recientemente, Ebrahimzadeh et al. (2018) fusionaron diferentes características lineales y no lineales tales como: energía, correlación, media, entre otras, con una red neuronal conocidas como perceptrón multicapa para predecir 12 minutos antes un infarto con una eficiencia del 88.29%. A pesar de los buenos resultados obtenidos por las investigaciones a nivel internacional, estos requieren de una gran cantidad de indicadores para poder ser eficientes en el diagnóstico anticipado de infartos, limitando su aplicación en sistemas debido a la gran carga computacional y gran tiempo de computo.

A nivel nacional, diferentes trabajos se han concentrado en el desarrollo de sistemas de adquisición de señales eléctricas del corazón. Por ejemplo, Ochoa et al. (2010) desarrollaron un sistema de adquisición de señales ECG basado en 4 módulos: protección al usuario contra regreso de corrientes, amplificación, filtrado y un dispositivo programable que permite transmitir la información a un equipo de cómputo para su posterior análisis. Este sistema permite obtener las señales eléctricas del corazón de manera eficiente para su posterior análisis mediante algún

sistema automático de clasificación, permitiendo complementar los resultados que pueda ser emitidos por un Médico. Por otro lado, Guardado-Medina y Vallin-González (2009) desarrollaron una aplicación mediante el análisis tiempo-frecuencia para la detección de patrones en patologías cardíacas, como los diferentes tipos de infarto al miocardio, usando la Transformada de Fourier. Con esta técnica se obtiene un análisis en frecuencia con el objetivo de poder reducir el ruido de la señal del complejo QRS, permitiendo diagnosticar y encontrar diferentes patologías cardíacas. De acuerdo con las investigaciones que se han venido realizando a nivel nacional, se observa que están enfocadas principalmente en el desarrollo de sistemas de adquisición de las señales eléctricas del corazón, además del desarrollo de sistemas monitoreo capaces de detectar cuando una persona presenta ya la enfermedad. Por ende, existe la necesidad de proponer metodologías basadas en procesamiento avanzado de señales capaces de diagnosticar anticipadamente el padecimiento.

A nivel local, dentro de la Universidad Autónoma de Querétaro, (Hernández, 2015) desarrolló un sistema basado en FPGA (Field Programmable Gate Array o arreglo de compuertas programables) para el monitoreo de señales cardíacas en ratas. Para ello, se propuso un diseño propio de amplificación, filtrado y conversión de los datos para poder adquirir este tipo de señales, ya que estas presentan una muy baja amplitud y están embebidas en bastante ruido. Hasta el momento este es el único trabajo de tesis realizado referente a la medición eléctrica de corazón, pero no al diagnóstico de enfermedades, por lo tanto, esta tesis contribuirá en el estado del arte de la UAQ con una metodología basada en procesamiento avanzado que sea capaz de analizar señales no estacionarias como son las ECG con el fin de generar un diagnóstico anticipado de hasta 14 minutos antes del infarto, lo que puede contribuir a reducir el número de muertes por esta causa, además de predecir con mayor tiempo de anticipación superando el tiempo de los trabajos publicados internacionalmente.

1.3 Descripción del problema

El diagnóstico anticipado de cualquier tipo de enfermedad es de suma importancia con el fin de tratarla de manera adecuada. En nuestro caso, como se había mencionado, las muertes por ataques al corazón son las de mayor número en el país. Por lo tanto, las técnicas de diagnóstico de estas patologías son de suma importancia para evitar y disminuir el número de muertes.

En la actualidad se están desarrollando múltiples campañas de salud para evitar que más personas sigan sufriendo de problemas del corazón. Sin embargo, pocas o ninguna de esa campaña se preocupa por el desarrollo de tecnologías que ayuden en este momento a las personas que ya están sufriendo alguna de las diferentes enfermedades cardíacas crónicas. Debido a la enorme cantidad de muertes por problemas cardíacos y en especial por infartos al miocardio, una de las posibles soluciones para disminuir ese número, es el desarrollo de técnicas de diagnóstico basadas en el análisis de señales ECG que permitan predecir el momento en que una persona puede sufrir un ataque al corazón; sin embargo, el análisis de señales ECG representa un reto, ya que presentan características no estacionarias de baja amplitud.

De esta manera mediante este trabajo de tesis se pretende realizar una metodología basada en procesamiento avanzado que permita el análisis de señales no estacionarias como las ECG con el fin diagnosticar anticipadamente un infarto y en base a ello llevar a la persona afectada realice acciones que minimicen los efectos que pueda tener el infarto.

1.4 Justificación

En la actualidad, la salud juega un papel medular en el desarrollo de la vida cotidiana, por lo que es primordial mantener al ser humano en buena condición o salud, ya que estamos sujetos a muchas enfermedades a lo largo de la vida, debido a una gran cantidad de padecimientos tales como diabetes, infartos, epilepsias, Alzheimer, cáncer, entre otras más. Por lo tanto, un sistema capaz de monitorear y

evaluar la salud de las personas en forma automática es altamente deseable, ya que se podría diagnosticar el estado de la persona y tomar acciones preventivas para mejorar la salud del paciente y prevenir la propagación de la enfermedad que puedan tener como consecuencia pérdidas humanas y económicas.

En particular, se han propuesto diferentes sistemas de monitoreo con metodologías basados en procesamientos avanzados para el diagnóstico anticipado de infartos empleando señales ECG; sin embargo, estos requieren de una gran cantidad de indicadores para poder ser eficientes en el diagnóstico anticipado de infartos, limitando su aplicación en sistemas debido a la gran carga computacional y gran tiempo de computo. Por estas razones, 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 la señales ECG con el fin de poder generar una metodología que sea capaz de poderse implementar en un sistema de monitoreo, logrando disminuir el número de muertes en el mundo y principalmente en México, siendo este el principal país donde las muertes por problemas cardiacos, son por infartos.

1.5 Hipótesis

Mediante la utilización de la teoría del caos y redes neuronales es posible generar una metodología que permita el diagnóstico anticipado de infartos de forma automática.

1.6 Objetivos

1.6.1 Objetivos Generales

Proponer y desarrollar una metodología basada en la teoría del caos (fractales de Katz, Higuchi y Dimensión de caja) y redes neuronales para el diagnóstico anticipado de infartos de forma automática.

1.6.2 Objetivos Particulares

1. Leer las señales ECG provenientes de la base de datos NSR y SCD mediante el uso del software MATLAB para su entendimiento y posterior procesamiento.
2. Programar los algoritmos de Katz, Higuchi y dimensión de caja haciendo uso del software MATLAB para estimar la fractalidad de una señal en el dominio del tiempo.
3. Analizar las señales ECG proporcionadas por el Hospital de Boston localizado en los Estados Unidos de América mediante los fractales programados en el objetivo 2, para discernir cual es capaz de distinguir entre una persona sana y una que sufrirá un infarto.
4. Analizar los valores de fractalidad estimados en el objetivo 3 mediante un análisis de varianza, ANOVA, para estimar cual(es) son los más discriminativos y asociarlos al fenómeno estudiado.
5. Diseñar un clasificador basado en redes neuronales empleando las características o valores de fractalidad más discriminantes para distinguir entre una persona sana y una que sufrirá un infarto 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 y confiable.

1.7 Planteamiento General

La Figura 1.1 muestra el planteamiento general de este trabajo de tesis, el cual consta de manera global de 3 bloques descritos a continuación:



Figura 1.1 Planteamiento general

1. **Señales ECG.** En este primer paso del planteamiento general es la lectura para el entendimiento de las señales ECG provenientes de la base de datos NSR y SCD, tanto de personas sanas y personas que fueron monitoreadas antes, durante y después del infarto, respectivamente, las cuales son de acceso libre.
2. **Procesamiento.** Como segundo paso, la etapa de procesamiento se encarga de encontrar características dentro de las señales ECG que permitan predecir una persona con posibilidad de sufrir un infarto y una persona con un ritmo cardíaco normal. Adicionalmente, un análisis estadístico para determinar cuál o cuáles características son las más útiles para el fenómeno estudiado en este trabajo de tesis son seleccionada en esta etapa.
3. **Clasificación.** Finalmente, una vez procesadas las señales e identificadas las características más discriminantes se realiza la clasificación de estas con el objeto de predecir entre una que tiene la posibilidad de sufrir un infarto y una que tiene características de un ritmo cardíaco sano de forma automática.


CAPÍTULO II

2.1 Revisión de la literatura

Tal como se muestra en el capítulo I, el principal propósito de este trabajo es desarrollar una metodología, la cual se basa en el análisis y procesamiento digital de señales ECG, la cual permita con un tiempo previo determinado, predecir el momento en que una persona pudiera padecer un infarto. En este capítulo II se desglosará la información necesaria, teoría y conceptos claves para entender de mejor manera la relación que existe entre las señales ECG, el software, y los métodos de procesamiento digital de señales tales como algoritmos y clasificadores requeridos para obtener información útil en las señales ECG que permitan la predicción de infartos.

2.2 Señales ECG

El electrocardiograma o señal ECG se encarga de registrar la diferencia de potencial de voltaje que genera el corazón, la cual es obtenida por medio de electrodos colocados en diferentes puntos preestablecidos en la superficie corporal como se muestra en la Figura 2.1.



- V1:** Entre el cuarto espacio intercostal y el borde derecho del esternón
- V2:** Entre el cuarto espacio intercostal y el borde izquierdo del esternón
- V3:** Entre V2 y V4
- V4:** En quinto espacio intercostal siguiendo la línea medio-clavicular
- V5:** Al nivel de V4, Pero sobre la línea axilar izquierda anterior
- V6:** Al nivel de V4, pero sobre la línea axilar izquierda media
- RA:** Al inicio de la mano derecha.
- LA:** Al inicio de mano izquierda
- RL:** A la altura del tobillo de la pierna derecha.
- LL:** A la altura del tobillo de la pierna izquierda

Figura 2.1. Ubicación de los electrodos en la superficie del cuerpo humano para la medición de señales ECG (grafico obtenido de un equipo de electrocardiograma WelchAllyn)

El funcionamiento de un electrocardiograma de basa en la interpretación de las diferencias de voltajes creadas entre las células miocárdicas, esto durante un intercambio de cargas, lo que polariza y despolariza el músculo cardiaco. Las derivaciones electrocardiográficas se encargan de realizar un registro del potencial eléctrico, dicho potencial eléctrico a su vez describe fuerzas eléctricas momentáneas que se están sumando. Estas fuerzas eléctricas se manifiestan secuencialmente al mismo tiempo que ocurre la polarización y repolarización.

Para la cuantificación de la actividad eléctrica se usa la unidad de potencial eléctrico voltios en su milésima parte que son los milivolts, lo que representa la amplitud de la señal y por otra parte los milisegundos representan la duración. Existen componente para la descripción la representación gráfica de la actividad

eléctrica cardiaca, dichos componentes son de alta y baja potencia representados por 5 diferentes tipos de ondas, las cuales se denominan: ondas P, Q, R S y T (ver Figura 2.2) Los cambios de alta velocidad en la señal correspondientes al complejo QRS se denominan componentes de alta frecuencia, mientras que las ondas establecidas como P, T y U se denominan componentes de baja frecuencia. Existen dos rangos de frecuencias principales en la descripción del trazo cardiaco, una de ellas es la frecuencia de, 10 Hertz en la cual se puede encontrar el complejo QRS, mientras que en la frecuencia de 100 Hertz se encuentra la información restante de la onda. (Pozas, 2011).




Figura 2.2 Ondas en el ritmo cardiaco

Clínicamente las unidades que se establecen para la descripción o expresión de la frecuencia cardiaca de un ser humano son los latidos por minutos, los cuales corresponden con la cantidad de contracciones cardiacas que ocurren por minuto; por ejemplo, si el paciente presenta una arritmia de tipo fibrilación auricular de frecuencia cardiaca de 120 latidos por minuto, se establecería que presenta 2 latidos por cada segundo, correspondiente a 2 Hertz ciclos por segundo de frecuencia, sin embargo de forma clínica es de más utilidad calcular el periodo existe entre dos latido, que sería para el ejemplo anterior de aproximadamente 0.5 segundos. En pocas ocasiones se pueden encontrar frecuencias por debajo de los 0.67 Hz, mientras que para frecuencias en adultos se habla de 150 Hz y 250 Hz para pediátricos. De esta manera se recomienda que para el análisis de estas señales

se usen filtros de alta y baja frecuencias en rangos de los 0.5 a 250 Hz (Pozas, 2011).

2.2.1 Sensores para medición de señales ECG

Un sensor transforma las variables físicas en señales principalmente eléctricas (Guerrero, 2010). Existen diversos sensores para la medición de fenómenos provenientes del cuerpo humano tales como electrodos, termómetros, cámaras termográficas, entre otros. Entre sus diversas características, los biosensores no producen efectos de carga sobre la fuente de la señal, además de que no son invasivos no requiere de cirugía para su uso), haciéndolos cómodos para el operario y usuarios.

En específico, los biosensores empleados para la medición de señales ECG son los electrodos. Existen diferentes tipos de electrodos tales como; electrodos para la adquisición superficial, interna, microelectrodos y electrodos para la estimulación (ver Figura 2.3). Los usos de estos distintos electrodos dependerán de la forma en que se quiere obtener la señal, además de la situación en la que el paciente o usuario se encuentre al momento de necesitar un estudio de este tipo. Regularmente para el monitoreo de señales ECG, como las analizadas en este trabajo de tesis, se usan electrodos superficiales no invasivos, los cuales están en contacto directo al cuerpo del paciente mediante un gel que permite la conductividad de la señal eléctrica producida por el corazón.




Figura 2.3 Diferentes tipos de electrodos

La funcionalidad del electrodo inicia cuando el elemento metálico del electrodo entra en contacto con el gel conductivo, se crea la interfaz en la que se involucra el electrodo y el gel, esta interfaz al estar en equilibrio crea un potencial de contacto. Cuando por esta interfaz se pasa corriente, el equilibrio existente cambia, lo que da lugar a una variación de tal potencial. Este potencial esta dado por la Ecuación (2.1):

$$\Delta V_p = V_s - V_c \quad (2.1)$$

donde ΔV_p es un incremento de tensión de polarización, mientras que V_s es el potencial de la semicélula durante el paso de corriente y, por último V_c representa el potencial existente al contacto. Si bien decimos que el gel conductivo es independiente de la corriente, ΔV_p será cero, esto quiere decir que los electrodos son no polarizables o reversibles. Mientras que, si por lo contrario el gel está dado como función de la corriente, ΔV_p tendrá un valor diferente de cero y lo que determine el valor negativo o positivo de ΔV_p será de acuerdo a la dependencia del electrodo, esto quiere decir si los electrodos son polarizables o irreversibles. El electrodo más común y el más utilizado en investigaciones y monitores en hospitales, es el electrodo de plata-cloruro de plata (Ag-ClAg) (CENETEC, 2016)

2.3 Procesamiento Digital de Señales

El procesamiento digital de señales se encarga de transformar, representar y manipular señales tanto en tiempo como imágenes, con el fin de identificar o estimar características dentro de estas que permitan asociarlas a diferentes fenómenos tales como fallas en motores, en edificios o al comportamiento humano (Amezquita-Sanchez et al. 2017). El procesamiento digital de señales se realiza principalmente en softwares tales como Visual Studio, LabVIEW, Matlab, entre otros, siendo Matlab el software más empleado para el análisis de señales debido a que es un software de alto nivel, lo que permite la manipulación de la información de manera sencilla y eficiente.

2.3.1 MATLAB

MATLAB es un software de alto nivel que permite la manipulación o cálculo matricial o vectorial de señales digitales, ofreciendo un entorno de desarrollo integrado, esto quiere decir, que es una herramienta que permite con solo una aplicación ejecutar ordenes sencillas, escribir programas a través de un editor integrado, copiarlos, depurarlos y realizar graficas que permiten interpretar los resultados obtenidos (Echeverria, 2017).

Matlab cuenta con un lenguaje de programación propio, muy similar a los utilizables habitualmente en el cálculo numérico tales como GeoGebra y Scilab, pero con más simplicidad y más tolerante en su sintaxis, lo que permite desarrollar scripts (conjunto de comandos escritos en un fichero, que se pueden ejecutar con ordenes únicas) propios al usuario, así como funciones o descripción de algoritmos, lo que reduce la cantidad de líneas del código y simplifica la resolución de problemas complejos. Además, Matlab cuenta con una vasta cantidad de cajas de herramientas, añadiendo una funcionalidad especializada en la resolución de problemas específicos.

Matlab presenta una interfaz gráfica, como se muestra en la Figura 2.4, la cual a su vez está dividida en 5 ventanas llamadas: espacio de trabajo, ventanas de comandos, historia de comandos, detalles y carpeta actual. (Echeverria, 2017). La ventana, espacio de trabajo, permite visualizar las variables empleadas, así como el o los valores asignados a estas. La ventana de comandos es el área de trabajo o de desarrollo del usuario, la cual permite aplicar o generar algoritmos para analizar la o las señales digitales. Por otro lado, en la ventana, historia de comandos, se visualiza el historial de los comandos que se han estado empleando o ejecutando. La ventana, detalles, se encarga de mostrar los comentarios acerca del trabajo, así como posibles problemas que podrían surgir. Finalmente, la ventana, carpetas actuales, muestra la carpeta donde se encuentran los archivos utilizados en el proyecto.

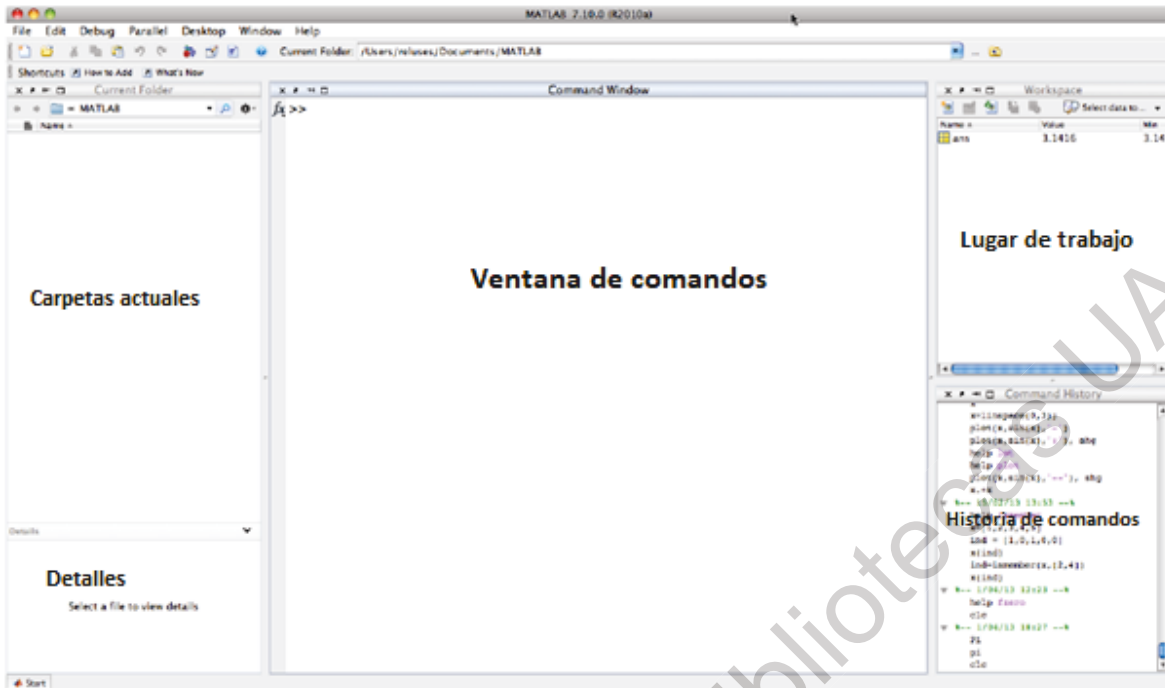


Figura 2.4 Ventana de inicio de Matlab

2.3.2 Dimensión Fractal.

Dimensión fractal o Fractal Dimensión por sus siglas en ingles FD es una medida dinámica no lineal utilizada para cuantificar la complejidad geométrica de las señales en el tiempo. Dicho de otra manera, la Dimensión Fractal mide la regularidad y la similitud que existe entre la misma señal (Amezquita-Sanchez y Adeli, 2015).

De acuerdo a las similitudes encontradas en la señal, el valor de fractalidad para una señal en tiempo tiende entre 1 y 2, donde 1 indica que la señal tiene una cantidad baja de similitud, mientras que los valores acercados a 2 indican que la señal analizada tiene una cantidad alta de similitudes. Por lo tanto, el método de FD es considerado una herramienta adecuada para el análisis de las señales no estacionarias tales como las señales ECG ya que estas pudieran cambiar su forma geométrica antes del infarto (Amezquita-Sanchez et al. 2017).

Para la estimación de la FD de una señal existen distintos algoritmos que son capaces de interpretar irregularidades y auto-similitud de manera diferente por esta razón tres algoritmos: Katz (KFD), Higuchi (HFD) y dimensión de caja (BD) son estudiados para evaluar el valor de fractalidad de una señal ECG, con el fin de poder diferenciar entre un corazón con latido sano y uno que pudiera presentar un infarto.

2.3.2.1 Algoritmos de Katz.

El algoritmo de Katz se basa en la variación de las distancias existentes entre dos puntos consecutivos que puede medir la fractalidad de una señal de acuerdo con la Ecuación (2.2) (Katz,1998):

$$KFD = \ln\left(\frac{L}{a}\right) \ln\left(\frac{d}{a}\right) \quad (2.2)$$

donde L y a son la suma y el promedio de las distancias Euclidianas entre muestras sucesivas de la señal en tiempo x con N muestras, respectivamente (Ecuaciones 2.3 y 2.4), y d es la distancia máxima entre la primera muestra x_i y la muestra x_{i-1} .

$$L = \sum_{i=2}^N |x_i - x_{i-1}| \quad (2.3)$$

$$a = \frac{L}{N-1} \quad (2.4)$$

2.3.2.2 Algoritmos de Higuchi

El algoritmo de Higuchi calcula en cuatro pasos la fractalidad de una determinada señal de serie de tiempo (Higuchi,1998), dichos pasos se describen de la siguiente manera:

Paso 1: Se descompone la señal de serie de tiempo original x con N muestras en nuevas señales con una secuencia x_m^k

$$x_m^k = x_m, x_{m+k}, x_{m+k2}, \dots, x_{m+\lfloor \frac{N-m}{k} \rfloor k} \quad (m = 1, 2, \dots, k) \quad (2.5)$$

donde k y m están representando el valor escalar, esto para que se determine el periodo de tiempo de retardo consecuente entre las muestras y también el tiempo de muestras iniciales respectivamente. Por ejemplo, si $N = 100$ y $k = 3$, las secuencias nuevas estarán construidas o dadas de la siguiente manera:

$$\begin{aligned} x_3^1 &= x_1, x_4, x_7, \dots, x_{97}, x_{100} \\ x_3^2 &= x_2, x_5, x_8, \dots, x_{95}, x_{98} \\ x_3^3 &= x_3, x_6, x_9, \dots, x_{96}, x_{99} \end{aligned} \quad (2.6)$$

Paso 2: Calcular la longitud promedio normalizada para cada una de las secuencias x_m^k :

$$L_m(k) = \frac{N-1}{k \lfloor \frac{N-m}{k} \rfloor} \sum_{i=1}^{\lfloor \frac{N-m}{k} \rfloor} |x_{m+ik} - x_{m+(i-1)k}| \quad (2.7)$$

donde el término $\frac{N-1}{k \lfloor \frac{N-m}{k} \rfloor}$ representa el factor de normalización de cada una de las secuencias mostradas.

Paso 3: calcular la longitud total $L(k)$, mediante el promediado de la longitud de cada una de las secuencias $L_m(k)$ para cada uno de los valores k :

$$L_m(k) = \sum_{m=1}^k L_m(k). \quad (2.8)$$

Paso 4: modificar $k = k + 1$. If $k < k_{max}$ repitiendo los pasos de 1 a 3. El valor L_{max} es seleccionado para ser el numero cuando la inclinación de la mejor línea echa a la medida para el diagrama del plano planteado $\left(\ln[L(k)] \text{ versus } \ln\left[\frac{1}{k}\right] \right)$ permanece constante. La inclinación obtenida de la línea representa el valor de la fractalidad, de la señal que fue analizada. Los valores 32 y 64 para k son los más

adecuados para obtener correctamente el valor de fractalidad de una señal en tiempo con características no estacionarias tales como las señales ECG, es por ello que ambos son evaluados en este trabajo de tesis (Higuchi, 1998).

2.3.2.3 Dimensión de caja.

El método BD por sus siglas en inglés Box Dimension es otra manera de encontrar la fractalidad, principalmente para imágenes y algunas otras superficies. Sin embargo, Wang en 2005 presentó una adaptación de este método para poder analizar señales de series de tiempo $x(x_1, x_2, \dots, x_N)$ que contienen un N número de muestras. Esta adaptación del método de BD es definido como el algoritmo natural de la suma de las diferencias existentes entre dos pruebas consecutivas de un intervalo de tiempo de muestreo, Δt , que lo divide el algoritmo natural Δt , que es dado por la Ecuación (2.9) (Wang, 2005):

$$BD \cong \frac{\ln\left(\sum_{i=1}^{N-1} \frac{|x_{i+1} - x_i|}{\Delta t}\right)}{\ln(\Delta t)} \quad (2.9)$$

2.3.2.4 Análisis de Varianza.

El análisis de varianza o ANOVA es un análisis estadístico donde su principal función es evaluar la capacidad de una o varias características, esto con el propósito de discriminar grupos (Pakyar y Malakrishman, 2012). Para realizar esta evaluación, un valor de probabilidad, valor P, es calculado. Este valor de P es variante entre 0 a 1. Si el valor P tiende a 0 quiere decir que las características analizadas tienen una alta capacidad para discriminar entre los grupos; pero si de lo contrario el valor P tiende a 1, indica que las características analizadas presentan una baja capacidad para discriminar los grupos. De esta manera, el valor P es empleado para

determinar los valores FD más discriminativos para asociarlos al fenómeno estudiado.

2.3.2.5 Redes Neuronales Artificiales

Las redes neuronales se basan en modelos del comportamiento de las neuronas vivas y redes de comunicación de un ser humano (Deperlioglu y Kose, 2011). Una neurona viva toma el papel de un nodo en una red neuronal artificial, el papel de nodo en una red neuronal es de una función de suma no lineal para procesar la información. Las conexiones neuronales (fuerzas sinápticas) son traducidas en factores de ponderaciones que ocurren a lo largo de las interconexiones de la red. Dentro de las redes neuronales, esos pesos establecidos son ajustados mediante un proceso de entrenamiento, debido a este entrenamiento, los valores de entrada, así como los valores de salida correspondientes, son enviados repetitivamente a la red. Los pesos son ajustados en cada repetición, con el propósito de acercar los valores de salida de la red, a los valores deseados. Es propósito de cada neurona específica es dedicarse a funciones de salida o entrada, además que algunas otras capas ocultas se hacen internas a la red creando una configuración de Perceptrón Multicapa para procesamiento de información más específico, tal como se muestra en la Figura 2.5 (Hernandez-Vargas et al. 2014).




Figura 2.5 Estructura de un Perceptrón Multicapa en una Red Neuronal (Hernández-Vargas et al. 2014).

Cada una de las neuronas es un nodo N_j sumador no lineal, que se define en la siguiente ecuación

$$\sum_{i=0}^n P_{ji} A_i \quad (2.10)$$

donde P_{ji} es el valor de ponderación para cada unidad i de la neurona j ($j = 1, 2, \dots, 5_2$) y A_i es el valor de activación definido por:

$$A_i = \frac{1}{1 + \exp(-P_j)} \quad (2.11)$$

Dirección General de Bibliotecas UAQ

CAPÍTULO III

3.1 Metodología.

La Figura 3.1 muestra la metodología propuesta para el desarrollo de este trabajo de tesis, cuyo objetivo es la predicción o diagnóstico anticipado de un posible infarto.




Figura 3.1 Diagrama de bloques de la metodología propuesta.

La metodología propuesta consiste en 4 pasos, los cuales son descritos a continuación:

Paso 1. Primeramente, las señales ECG provenientes de las ambas bases de datos NSR y SCD son segmentadas o divididas en ventanas de 1 minuto de tiempo para su posterior análisis. En este sentido, por un lado, las señales ECG de la base datos SCD son divididas en ventanas de 1 minuto hasta 14 minutos antes del infarto. Por otro lado, las señales ECG correspondientes a las personas sanas, se selecciona una ventana de 1 minuto al azar de cada paciente para su análisis. Es muy importante mencionar que la selección de 14 minutos antes del infarto es con el fin de mejorar los tiempos reportados por otros trabajos a nivel internacional, así como la precisión para poder predecir un posible infarto. Además, la selección de ventanas de 1 minuto es debido principalmente a que estas permiten tener la cantidad suficiente de información para poder ser procesadas de manera correcta por las diferentes técnicas de procesamiento (Amezquita-Sanchez et al. 2018). La

Figura 3.2 muestra un ejemplo de la segmentación de las señales ECG para ambas bases de datos.

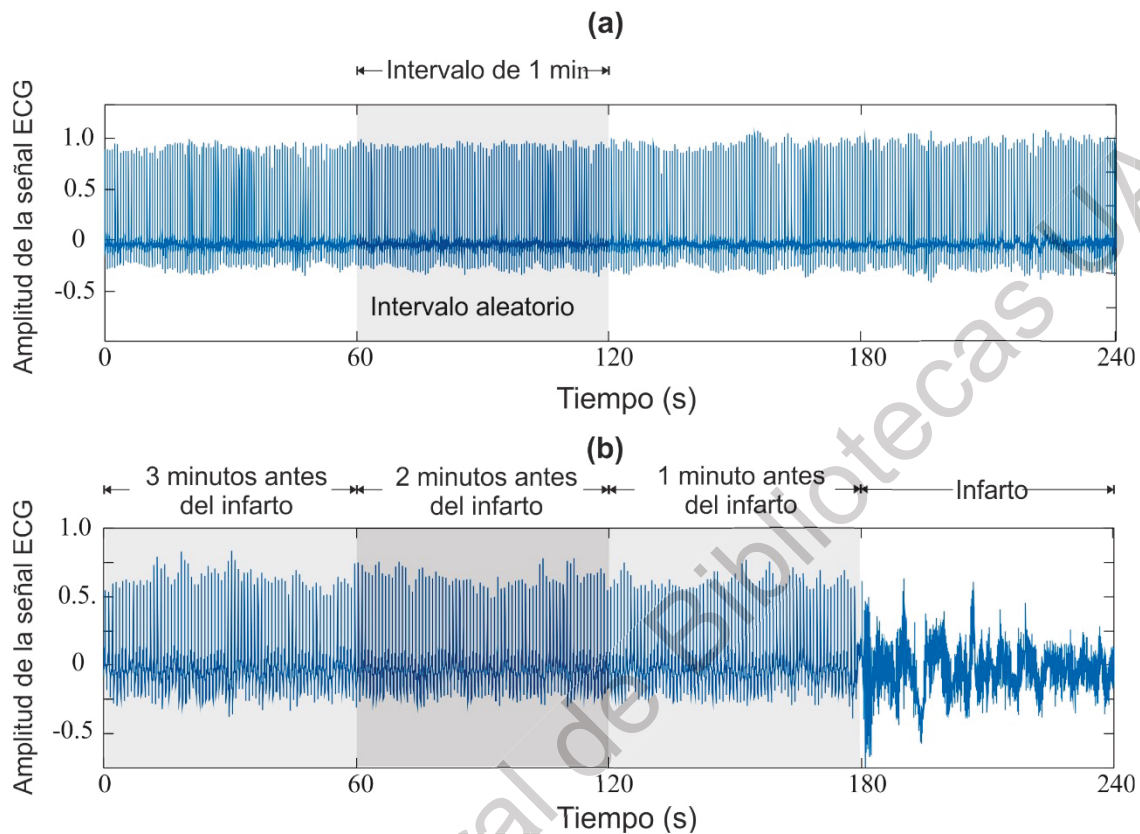


Figura 3.2. Segmentación de las señales ECG para un paciente con ritmo cardiaco (a) sano y (b) con infarto.

Paso 2. Una vez segmentadas o divididas las señales ECG de ambos grupos, estas ventanas de datos son analizadas por los diferentes algoritmos de dimensión fractal, KFD, HFD y BD, los cual permiten estimar la regularidad geométrica de las señales (Mandelbrot, 1982), y esta ser empleada como característica para poder predecir de forma anticipada un infarto. Es muy importante mencionar que se seleccionó la dimensión fractal para el análisis de las señales ECG, ya que esta permite la evaluación de la geometría de la señal y en base a esto una persona sana mantiene un patrón geométrico debido al complejo PQRST, el cual si es alterado el valor del fractal también cambiara.

Paso 3. Como tercer paso, los distintos valores de fractalidad son analizados por medio de un análisis estadístico llamado ANOVA con el fin de estimar o identificar cual o cuales fractales son los más capaces de discernir entre una persona sana y una que sufrirá un infarto.

Paso 4. Finalmente, una vez identificadas las características más discriminantes, estas son empleadas para entrenar una red neuronal artificial con el fin de predecir o diagnosticar anticipadamente hasta 14 minutos antes un posible infarto de manera automática.

3.2 Material

Con el fin de validar la metodología propuesta en este trabajo de tesis, las señales ECG de las bases de datos de acceso libre tituladas NSR (NSR, 2018) y SCD (SCD, 2018) fueron empleadas. Las bases incluyen las señales ECG de 41 personas, 23 con muerte cardiaca repentina con un rango de edades de entre 17 y 82 años, y 18 personas con ritmo cardiaco normal con un rango de edades de entre 20 y 50 años. Es importante mencionar que de las 23 personas en la base de datos SCD, solamente 20 personas presentaron un infarto y es por ello que solamente esas 20 señales de ECG son usadas para para evaluar la propuesta (Fujita et al. 2016). La Tabla 3.1 resume la información clínica de las personas que sufrieron un infarto.

Tabla 3.1. Información clínica de los pacientes participante que sufrieron un infarto

| No. De Paciente | Género | Edad | Historial | Medicación | Ritmo Cardiaco Subyacente |
|-----------------|-------------|------|---|-------------------------------------|---|
| 1 | Masculino | 43 | Desconocido | Desconocida | Sinusal |
| 2 | Femenino | 72 | Falla cardiaca | Digoxina; gluconato de quinidina | Sinusal |
| 3 | Desconocido | 62 | Injerto de bypass coronario; Historial de arritmias | Procan SR; bloqueador beta | Sinusal con demanda intermitente de estimulación ventricular; RCP en el momento de la prueba cardiaca |
| 4 | Femenino | 30 | Desconocido | Desconocida | Sinusal |
| 5 | Masculino | 34 | Desconocido | Desconocida | Sinusal |
| 6 | Femenino | 72 | Reemplazo de válvula mitral | Digoxina | Fibrilación atrial |

| | | | | | |
|----|-------------|-------------|---|---|---------------------------------------|
| 7 | Masculino | 75 | Cirugía cardiaca | Digoxina; quinidina | Fibrilación atrial |
| 8 | Femenino | 89 | Desconocido | Desconocida | Fibrilación atrial |
| 9 | Desconocido | Desconocida | Desconocido | Desconocida | Sinusal |
| 10 | Masculino | 66 | Leucemia mielogénica aguda | Digoxina; quinidina | Sinusal |
| 11 | Masculino | Desconocida | Desconocido | Desconocida | Sinusal |
| 12 | Masculino | 35 | Enfermedad de arteria coronaria | Desconocida | Estimulación ventricular intermitente |
| 13 | Masculino | Desconocida | Desconocido | Desconocida | Sinusal |
| 14 | Masculino | 68 | Ectopia Ventricular | Digoxina; gluconato de quinidina | Sinusal |
| 15 | Femenino | Desconocida | Desconocido | Desconocida | Sinusal |
| 16 | Masculino | 34 | Desconocido | Desconocida | Sinusal |
| 17 | Masculino | 80 | Desconocido | Desconocida | Sinusal |
| 18 | Femenino | 68 | Injerto de bypass de arteria coronaria; reemplazo de válvula mitral | Digoxina; quinidina; propranolol; potasio; diuréticos | Fibrilación atrial |
| 19 | Femenino | 67 | Desconocido | Desconocida | Sinusal con estimulación intermitente |
| 20 | Femenino | 82 | Falla cardiaca | No mencionado | Sinusal |

3.3 Análisis de fractalidad de señales ECG

Para mostrar a grandes rasgos el funcionamiento de los diferentes algoritmos de dimensión fractal, una señal sintética similar al ritmo cardiaco normal es analizada (Amezquita-Sanchez et al. 2018). La señal sintética tiene una amplitud de 2.4 mV muestreada a 100 Hz durante un tiempo de 60 s resultando en 6,000 muestras. La Figura 3.3 muestra la señal ECG en una venta de 10 s para de apreciar la señal con mayor claridad.




Figura 0.3 Señal ECG generada artificialmente.

Una vez que la señal sintética ECG es generada, los tres algoritmos de fractalidad, KFD, HFD y BD son aplicados para analizar dicha señal. La Tabla 3.2 resume los valores obtenidos para cada algoritmo de dimensión fractal. Observando los resultados mostrados en la tabla, esto son distintos debido a que cada uno de los algoritmos tiene su propia interpretación, además, la forma de cálculo de la fractalidad de cada algoritmo es distinto. Por esta razón, es de suma importancia el analizar los tres diferentes algoritmos de fractalidad para la identificación de patrones en la predicción de infartos.

Tabla 0.2 Valores de los diferentes algoritmos de dimensión fractal para la señal sintética

| Algoritmo | Valor |
|-----------|-------|
| KFD | 1.38 |
| HFD-32 | 1.67 |
| HFD-64 | 1.81 |
| BD | 1.64 |

CAPÍTULO IV

4.1 Puesta de experimento

Las señales ECG de las bases de datos fueron monitoreado durante 24 horas usando una frecuencia de muestreo de 250 Hz para el grupo de SCD y 128 Hz para el grupo normal; respectivamente, y digitalizada con un convertidor analógico a digital de 12 bits (Greenwald, 1986). Con el fin de mantener una consistencia entre ambas bases de datos, las señales ECG del grupo de SCD son re-muestreadas o re-sampleadas de 250 Hz a 128 Hz para coincidir con la frecuencia de muestreo del grupo normal. El re-muestreo o re-sampleo se lleva a cabo por medio de convulsionar la señal ECG con un filtro de respuesta de impulso finito (FIR) de paso bajo. De las 24 horas registradas para cada paciente SCD, únicamente los 14 minutos antes del inicio del infarto son extraídos e investigados para el desarrollo de este trabajo. Esta ventana de tiempo se elige con el objetivo de proporcionar una detección SCD anterior a la proporcionada por otros trabajos analizados al inicio de este trabajo. Esos 14 minutos son segmentados en intervalos de 1 minuto (por ejemplo, el primer intervalo de un minuto, el segundo intervalo de un minuto, el tercer intervalo de un minuto y así sucesivamente hasta llegar al catorceavo intervalo de un minuto antes del inicio del infarto. Por otra parte, del grupo normal, un intervalo de un minuto de cada señal ECG tomada es extraída arbitrariamente en orden para encontrar diferencias entre las señales de los pacientes con SCD y los normales o sanos. La Figura 4.1(a) muestra una señal ECG de dos minutos de una persona con un ritmo cardiaco normal. La Figura 4.1(b) ilustra una señal ECG un minuto antes del que ocurra el infarto y un minuto posterior al inicio del infarto. Observando ambas figuras, diferencias substanciales entre ambas antes del inicio del infarto no pueden ser visualizadas. Por consiguiente, una metodología basada en técnicas de procesamiento avanzado como los fractales ayudará a identificar patrones que permita diferenciar entre las señales ECG pacientes sanos y las

señales ECG del paciente que pueden sufrir un infarto hasta 14 minutos antes del evento.

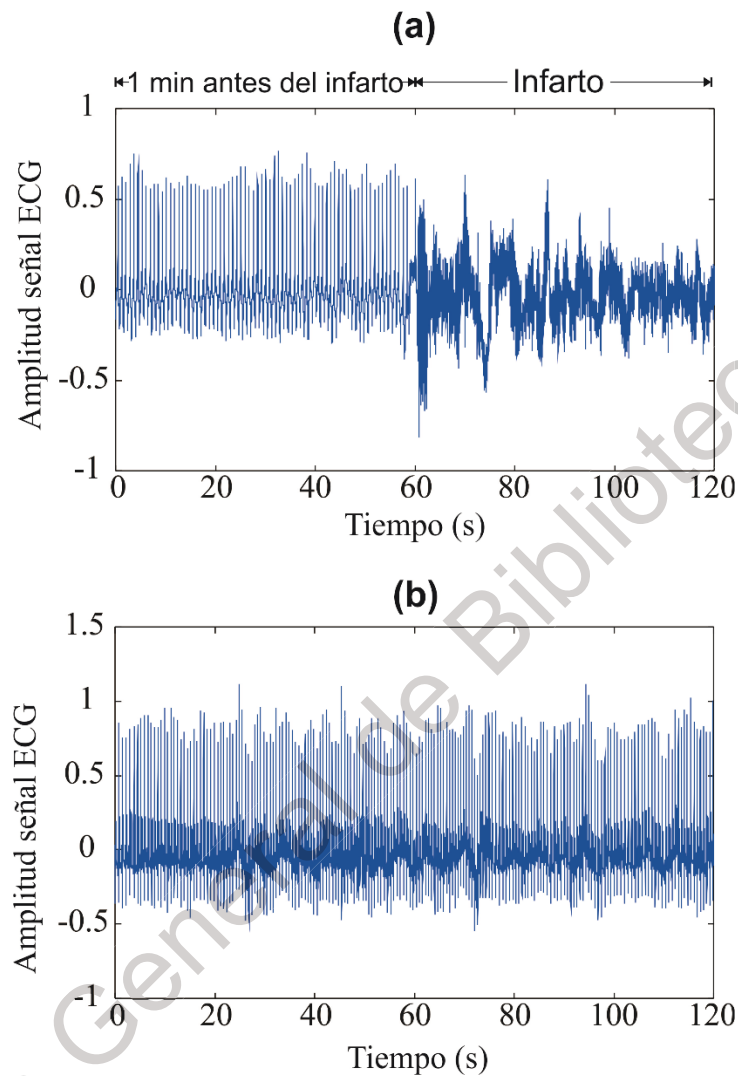


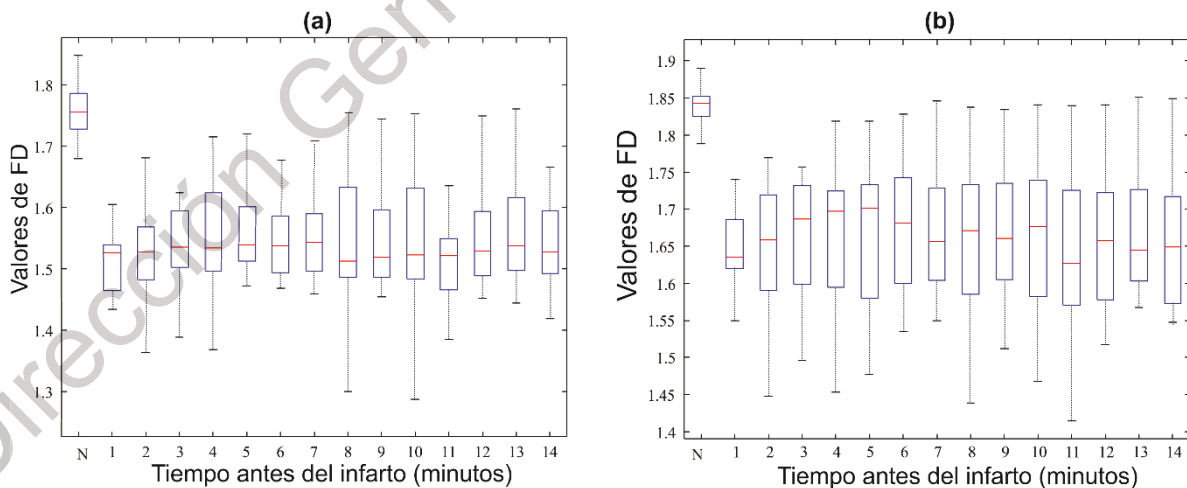
Figura 4.1. (a) Señal ECG 1 antes del infarto y 1 minuto después del inicio del infarto y (b) señal ECG con un ritmo cardiaco sano

4.2 Resultados

De acuerdo con los pasos de la metodología propuesta, las señales ECG monitoreadas de ambas bases de datos son divididas en intervalos de 1 minuto hasta 14 minutos antes del infarto y estos segmentos son analizados por los

diferentes indicadores no lineales, HFD, BD y KFD, con el fin de estimar patrones o características dentro de estas señales para poder predecir un posible infarto. Una vez estimados los valores de fractalidad para los diferentes segmentos de la señal ECG, estos son evaluados por medio de ANOVA para determinar cuál o cuáles indicadores no lineales son los más capaces de diferencias entre una señal ECG con un ritmo cardiaco sano y una que presenta características de un posible infarto. La Figura 4.2 muestra mediante un (diagrama de caja) la distribución de los valores de fractalidad obtenidos para HFD (32 y 64), así como para BD y KFD para los dos tipos de señales ECG: ritmo cardiaco normal (denotado por una N en la figura) y ritmo cardiaco susceptible a sufrir un infarto hasta 14 minutos antes del inicio del episodio de SCD.

De acuerdo con lo resultados obtenidos usando ANOVA y en base a los resultados presentados en la Figura 4.2, el indicador no lineal HFD para 32 y 64 es el más adecuado para evaluar el ritmo cardiaco de una persona con el fin de poder predecir un posible infarto hasta 14 minutos antes del evento. Por otro lado, los otros indicadores BD y KFD presentan traslapes entre los valores de un ritmo cardiaco sano y uno con posibilidad de un infarto, por lo tanto, estos son descartados.



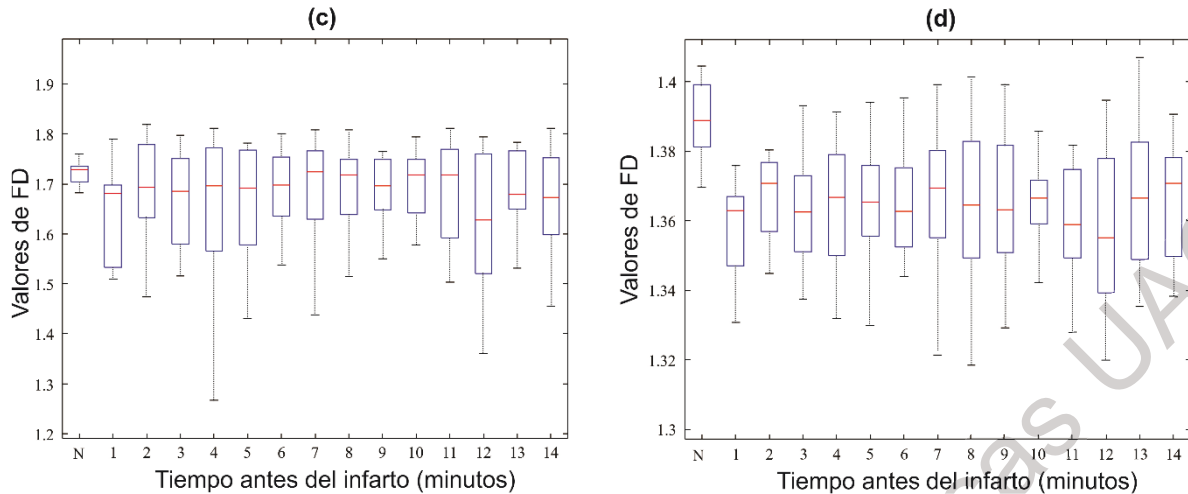


Figura 4.2 Distribución de los valores de FD obtenidos para (a) HFD-32, (b) HFD-64, (c) BD y (d) KFD para las señales de ECG de personas con ritmo cardiaco normal (N) y personas que sufrieron un infarto en intervalos de 1 minuto, empezando desde el minuto 1 hasta el minuto 14 antes del infarto

En la Tabla 4.1 se resume la media (μ) y la desviación estándar (σ) de los valores de fractalidd obtenidos para HFD 32 y 64 así como los valores de probabilidad (valor-p) de ANOVA asociados a los 14 intervalos de un minuto desde el minuto 1 hasta el minuto 14 antes del SCD, donde se puede observar que los valores de P son en promedio <0.0000001 , indicando que HFD es un buen índice para predecir un infarto hasta 14 minutos antes del evento.

Tabla 4.1. Características más discriminantes del análisis de FD y ANOVA para las señales normales en los 14 intervalos de 1 minuto, 14 minutos antes del evento SCD.

| Algoritmo de FD | Intervalos de 1 minuto señal normal (a+b) | Intervalos de SCD ($\mu \pm \sigma$) | | Valor-P |
|-----------------|---|--|-----------------|------------------------|
| HFD-32 | 1.75 ± 0.04 | minuto 1 | 1.52 ± 0.07 | 1.11×10^{-12} |

| | | | | |
|-----------|-----------------|-----------|-----------------|------------------------|
| | | minuto 2 | 1.52 ± 0.07 | 4.09×10^{-12} |
| | | minuto 3 | 1.53 ± 0.06 | 1.04×10^{-12} |
| | | minuto 4 | 1.54 ± 0.08 | 2.32×10^{-10} |
| | | minuto 5 | 1.54 ± 0.09 | 1.40×10^{-9} |
| | | minuto 6 | 1.53 ± 0.09 | 1.44×10^{-9} |
| | | minuto 7 | 1.54 ± 0.10 | 2.20×10^{-9} |
| | | minuto 8 | 1.53 ± 0.12 | 2.39×10^{-9} |
| | | minuto 9 | 1.53 ± 0.10 | 1.47×10^{-9} |
| | | minuto 10 | 1.53 ± 0.10 | 4.60×10^{-9} |
| | | minuto 11 | 1.51 ± 0.10 | 1.91×10^{-9} |
| | | minuto 12 | 1.53 ± 0.10 | 2.24×10^{-9} |
| | | minuto 13 | 1.54 ± 0.10 | 3.49×10^{-9} |
| | | minuto 14 | 1.53 ± 0.11 | 6.95×10^{-9} |
| | | HFD-32 | 1.83 ± 0.04 | minuto 1 |
| minuto 2 | 1.64 ± 0.08 | | | 1.65×10^{-9} |
| minuto 3 | 1.66 ± 0.09 | | | 3.18×10^{-9} |
| minuto 4 | 1.67 ± 0.08 | | | 7.64×10^{-8} |
| minuto 5 | 1.67 ± 0.09 | | | 1.65×10^{-7} |
| minuto 6 | 1.67 ± 0.08 | | | 1.41×10^{-7} |
| minuto 7 | 1.67 ± 0.08 | | | 5.63×10^{-8} |
| minuto 8 | 1.66 ± 0.10 | | | 2.26×10^{-7} |
| minuto 9 | 1.66 ± 0.08 | | | 1.54×10^{-8} |
| minuto 10 | 1.66 ± 0.09 | | | 1.43×10^{-7} |
| minuto 11 | 1.64 ± 0.10 | | | 3.77×10^{-8} |
| minuto 12 | 1.64 ± 0.08 | | | 1.29×10^{-8} |
| minuto 13 | 1.66 ± 0.07 | | | 6.51×10^{-9} |
| minuto 14 | 1.65 ± 0.08 | | | 1.24×10^{-8} |

Finalmente, una vez seleccionado el índice no lineal más discriminante para poder predecir un evento SCD, los valores del indicador no lineal son empleados para entrenar una red neuronal llamada perceptrón multicapa para predecir de forma automática un evento de SCD. La red neuronal está compuesta de 2 entradas, las cuales corresponden con el número de características seleccionadas, 10 neuronas en la capa oculta y dos salidas, las cuales corresponden con el diagnóstico del ritmo cardíaco (sano o posible SCD). La cantidad de neuronas en la

capa oculta fue seleccionada de forma experimental con el fin de obtener la mayor eficiencia por la metodología propuesta.

Es importante mencionar que para la etapa de entrenamiento de la red neuronal se empleó el algoritmo llamado Levenberg-Marquardt y funciones de activación sigmoideas logarítmicas con el fin de garantizar que la red neuronal entendiera la pertenencia de cada conjunto de datos (Amezquita-Sanchez et al. 2018). En la fase de entrenamiento de la red neuronal, se generaron 400 datos aleatorios entre los valores máximos y mínimos del 50% de los valores de HFD, 10 sujetos con SCD y 9 sujetos N (seleccionados de forma aleatoria), para cada condición: sana y con SCD, esto con el fin de que la red neuronal tuviera la mayor cantidad de información para la generar una asociación correcta de los conjuntos de datos al fenómeno estudiado. El resto de los valores de HFD perteneciente a 10 sujetos con SCD y 9 sujetos N son utilizados para validar la eficiencia de la red neuronal. La Tabla 4.2 resume la eficiencia de la metodología minuto a minuto hasta el 14^{vo} minuto antes del infarto, donde se puede apreciar que la metodología tiene una eficiencia global del 91.4% para predecir entre una persona sana y una que sufrirá un infarto.

Tabla 4.2. Eficiencia de la metodología propuesta minuto a minuto durante los 14 minutos anteriores al SCD.

| Tiempo previo al infarto(min) | Porcentaje (%) |
|-------------------------------|----------------|
| 14 | 90 |
| 13 | 90 |
| 12 | 90 |
| 11 | 90 |
| 10 | 90 |
| 9 | 90 |
| 8 | 90 |
| 7 | 80 |
| 6 | 90 |

| | |
|-----------------|-------------|
| 5 | 90 |
| 4 | 90 |
| 3 | 100 |
| 2 | 100 |
| 1 | 100 |
| Promedio | 91.4 |

4.3 Discusión de Resultados

Los resultados obtenidos muestran que la metodología propuesta a través de la dimensión fractal, en específico el fractal de Higuchi, permite predecir con gran exactitud en promedio del 91.4% hasta 14 minutos antes un infarto. La predicción de un infarto 14 minutos antes de su aparición es una tarea bastante complicada debido a que la señal ECG presenta cambios muy ligeros en comparación a una señal ECG normal. Por esta razón, la mayoría de las personas no perciben los síntomas o signos antes del evento. La propuesta hecha en este trabajo de tesis es capaz de identificar estos ligeros cambios en las señales ECG para poder predecir un infarto.

En los últimos años, diversas metodologías han sido propuestas para predecir infartos, las cuales se han basado en diferentes mediciones tales como entropía, correlación, exponente de Hurst, entre otros (Acharya et al. 2015, Fujita et al. 2016, Ebrahimzadeh et al. 2018). Sin embargo, a pesar de los buenos resultados mostrados, estas requieren la fusión de varios índices lo que incrementa la carga computacional, limitando un resultado en tiempo real. Por lo tanto, la dimensión fractal de Higuchi demuestra ser un método eficiente, ya que solamente una característica es empleada para predecir un infarto. La Tabla 4.3 muestra un resumen los trabajos más recientes publicados y la propuesta hecha en este trabajo de tesis para la detección anticipada de infartos. Esta incluye el tiempo de predicción y la eficiencia en porcentaje para predecir el infarto. Observando esta tabla y los resultados obtenidos, la metodología propuesta presenta las siguientes ventajas: (a)

requiere de una sola medida no lineal para poder predecir un infarto hasta 14 minutos antes de que este suceda, lo que permite obtener un resultado con pocas operaciones matemáticas en comparación con los trabajos previos, (b) un mayor tiempo antes del infarto, 14 minutos antes, con una mayor eficiencia, 91.4%, es obtenida en comparación al trabajo más actual presentado por Ebrahimzadeh et al. (2018), donde una eficiencia del 88.2% es obtenido hasta 12 minutos antes del infarto y (c) la señal ECG es analizada directamente sin la necesidad de una transformación de la misma que pudiera generar un retraso en el resultado.

Tabla 0.3 Resumen de resultados con su metodología propuesta de trabajos recientes que han usado la misma base de datos.

| Trabajo | Señal (ECG o HRV) | Metodología Propuesta | Tiempo de Predicción (Eficiencia %) |
|-------------------------------|-------------------------|---|---|
| Acharya et al. (2015) | ECG | <ol style="list-style-type: none"> 1. Transformada Wavelet Discreta para descomponer los datos en diferentes bandas de frecuencia. 2. El exponente de Hurst, la entropía aproximada, el análisis de fluctuación descendente, la dimensión de correlación para la extracción de características. 3. Máquina de Soporte Vectorial para la clasificación de características. | 4 min antes (92.11%) |
| Fujita et al. (2016) | HRV | <ol style="list-style-type: none"> 1. Estimación de la señal HRV a través del algoritmo Pan-Tompkins. 2. Entropía de Renyi, Entropía difusa, Parámetros de Hjorth, Entropía de Tsallis y la energía de la señal para la extracción de características. 3. Máquina de Soporte Vectorial para la clasificación de características. | 4 min antes (94.70%) |
| Ebrahimzadeh et al. (2018) | HRV | <ol style="list-style-type: none"> 1. Estimación de la señal HRV a través del algoritmo Pan-Tompkins. 2. Extracción de características: dominio del tiempo (media y desviación estándar de todos los intervalos RR, desviación estándar de diferencias entre intervalos RR adyacentes), tiempo-frecuencia (cantidad máxima y mínima de energía en cada ventana, diferencia entre la cantidad máxima y mínima de energía entre ventanas, desviación estándar entre la energía de las ventanas de tiempo) y no lineales medidas (desviación estándar de la variabilidad del intervalo RR a corto plazo y desviación estándar del intervalo RR a largo plazo). 3. Red Neuronal Artificial para la clasificación de características. | 12 min antes (88.29%) |
| Propuesta | ECG | <ol style="list-style-type: none"> 1. Dimensión Fractal para extracción de características. 2. Red Neuronal Artificial para la clasificación de características. | 14 min antes (91.4%) |

CAPÍTULO V

5.1 Conclusiones

En este trabajo se propuso una metodología en la cual el objetivo era obtener un tiempo y eficiencia de predicción, los cuales permitan realizar una acción medica evitando el SCD y de ese modo evitar que la persona muera. Entre más tiempo se logre anticipar el momento del infarto mediante este tipo de metodologías, aumenta la posibilidad de evitar una muerte por SCD

El procesamiento de las señales, usando las diferentes técnicas de procesamiento como KFD, HFD y BD para obtener las características de fractalidad, así como los análisis estadísticos y entrenamiento de las redes neuronales se realizaron el software MATLAB lo que hizo practico y eficiente la obtención de los resultados para la investigación. El uso de las diferentes técnicas de procesamiento permitió obtener mejores resultados, puesto que se pudo elegir de entre 5 métodos de fractalidad los más eficientes, y los que permitió tener mejores resultados al momento de usar las redes neuronales, pues una vez que las señales fueran analizadas y los datos de fractalidad obtenidos, estos se metieron a un análisis ANOVA, el cual indicaría que técnica de procesamiento sería la más adecuada para el análisis.

Se trabajo con dos tipos de señales, señales de pacientes sanos y pacientes que sufrieron SCD obtenida de una base de datos, las señales permitieron obtener dos tipos de resultados, unos ideales en donde todas las señales eran sanas y las cuales nos permitieron entrenar la red neuronal para obtener la eficiencia.

La eficiencia obtenida del 91.4% y el tiempo en el que nos dio esa eficiencia que fue de 14 minutos logro superar las expectativas que se tenían en un inicio, pues los tiempos y eficiencia revisados en investigaciones anteriores no superaban

los 94% en un máximo de 12 minutos, pero con procesamientos de señales con demasiada carga computacional, lo que hace muy lento e ineficaz la obtención de resultados. Mientras que con esta metodología se reduce el número de la carga computacional y número de resultados a analizar, mejorando la obtención de resultados.

Cabe mencionar la importancia que estos resultados tienen pues permiten aumentar el tiempo de acción médica en caso de llevar esta metodología a la aplicación en métodos de diagnóstico, por otro lado los resultados pueden ser útiles en investigaciones que como propósito tengan elevar el número de tiempo de anticipación al SCD y más que nada a la aplicación en la realización de un sistema de diagnóstico y monitoreo que permita estar conectado al paciente en forma continua a su señal eléctrica en tiempo real.

5.2 Prospectiva

Los resultados obtenidos en este trabajo resultaron favorables de acuerdo a lo esperado, sin embargo, buscar aumentar el tiempo de predicción aumentaría la posibilidad de evitar una muerte por infarto, además que, para procedimientos hemodinámicos, daría el tiempo suficiente para la intervención y para la aplicación de fármacos que darían el tiempo necesario para un traslado a un área de intervención, así como la llegada de especialista que realizarían la intervención quirúrgica hemodinámica.

Por otra parte usar otra u otras metodologías por ejemplo algoritmos de medición de patrones de entropía mejorarían la obtención de resultados, y no solo eso, también harían más eficiente la utilización de este tipo de metodología en un sistema de monitoreo y diagnóstico en tiempo real, el cual esté conectado y de manera remota a un monitor de signos vitales con trazo de ECG en el cual se podría observar la señal en tiempo real y a la vez ser analizada o comparada con la metodología de predicción para informar del peligro que tiene el paciente con problemas cardíacos de presentar un SCD.

También se podría pensar en un sistema de monitoreo y análisis de señal en tiempo real no necesariamente en pacientes o personas hospitalizadas, sino en monitoreo diario y común en personas que realizan sus actividades diarias normales, pues muchas veces los problemas cardiacos son presentados de la nada, esto debido a las variables causas que provocan los infartos. Existen los sistemas de monitoreo en pulseras y/o relojes de mano, lo importante sería el usar la metodología de predicción con el monitoreo diario.

Dirección General de Bibliotecas UAQ

Referencias.

- Acharya, U. R., Fujita, H., Sudarshan, V. K., Sree, V. S., Eugene, L. W. J., Ghista, D. N., & Tan, R. S. (2015b). An Integrated Index for Detection of Sudden Cardiac Death using Discrete Wavelet Transform and Nonlinear Features. *Knowledge-Based Systems*, 83(1), 149–158.
- Álvarez-Cedillo, J.A. (2010). Sistema Informático para análisis de Cardiopatía Holter. *SciELO*, 41(1), 59-66.
- 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., Valtierra-Rodriguez, M., Adeli, H., & Perez-Ramirez, C. A. (2018). A novel wavelet transform-homogeneity model for sudden cardiac death prediction using ECG signals. *Journal of medical systems*, 42(10), 176.
- Amezquita-Sanchez, J. P., Valtierra-Rodriguez, M., Perez-Ramirez, C. A., Camarena-Martinez, D., Garcia-Perez, A., & Romero-Troncoso, R. J. (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.
- CENETEC(2006),http://www.cenetec.salud.gob.mx/descargas/biomedica/guias_tecnologicas/17gt_electrocardiografos.pdf
- Deperlioglu, O., & Kose, U. (2011). An educational tool for artificial neural networks. *Computers & Electrical Engineering*, 37(3), 392-402.
- Ebrahimzadeh E., Manuchehri, M. S., Amoozegar, S., Araabi, B. N., & Soltanian-Zadeh, H. (2018). A time local subject feature selection for prediction of sudden cardiac death from ECG signal. *Medical & biological Engineering & Computing*, 56(1), 1253-1270.

Echeverria, R. 2017. Apuntes MAT-LAB Orientados a Métodos Numéricos elementales, Universidad de Sevilla. Sevilla. Apuntes.

EXCELSIOR(2017),<http://www.excelsior.com.mx/nacional/2017/05/29/1166332>,
Accesada 5 octubre 2017.

Excelsior. (2017). <https://www.excelsior.com.mx/nacional/2017/05/29/1166332>.

Fujita, H., Acharya, U. R., Sudarshan, V. K., Ghista, D. N., Sree, S. V., Eugene, L. W. J., & Koh, J. E. (2016). Sudden cardiac death (SCD) prediction based on nonlinear heart rate variability features and SCD index. *Applied Soft Computing*, 43(1), 510-519.

Guardado-Medina, R.O., & Vallin-González, D. (2009). Aplicación Del Análisis Tiempo-Frecuencia Eletrocardiografía. *Energy and Technology for the Americas: Education, Innovation, Technology and Practice*, 7, WE1-9.

Guerrero, J. 2010. Ingeniería Biomédica. Universidad de Valencia, Valencia. Tesis de Mestria.

Hernández-Morales, V.H. (2015). Desarrollo de un sistema para la adquisición de señales biométricas en roedores (Tesis Licenciatura). Universidad Autónoma de 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.

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

IMFR, (2019). <https://www.clubensayos.com/Ciencia/INFARTO-AL-MIOCARDIO-FACTORES-DE-RIESGO/2857118.html>

INEGI(2015),<http://www.inegi.org.mx/est/contenidos/proyectos/registros/vitales/mortalidad/tabulados/ConsultaMortalidad.asp>, Accesada 1 octubre 2017.

- Katz, M. J. (1988). Fractals and the analysis of waveforms. *Computers in biology and medicine*, 18(3), 145-156.
- Kuncheva, L. (2008). Fuzzy classifiers. *Scholarpedia*, 3(1), 2925. <https://doi.org/10.4249/scholarpedia.2925>
- Mandelbrot, B. B., & Pignoni, R. (1983). *The fractal geometry of nature* New York. WH freeman.
- Murugappan M., Murukesan L. Iqbal O., Sabira K. and Murugappan S. (2015). Time Domain Features Based Sudden Cardiac Arrest Prediction Using Machine Learning Algorithms. *Journal of Medical Imaging and Health Informatics*, 5(6), 1267-1271.
- NHS(2008), http://www.nhs.uk/translationspanish/Documents/Hearts_attack_Spanish_FINAL.pdf, Accesada 30 septiembre 2017.
- NSR. (2018). The MIT-BIH Normal Sinus Rhythm Database. Retrieved January 8, 2019, from <https://physionet.org/physiobank/database/nsrdb/>.
- Ochoa, A., Maciel, M., Estrada, F., Díaz, C., Felix, R., Álvarez, J. (2010). Sistema de Adquisición y Procesamiento de Señales Electrocardiograficas. *Sistema, Cibernetica e informática*, 7, 10-15.
- Pakyari, R & Malakrishman, N. A general-purpose approximate goodness of-fit for progressively Type II censored data. *IEEE Trans. Reliab*, 61, 238-244
- Pozas, G. G., (2011). El electrocardiograma y su tecnología, *Advance*, 4(24) 27-31.
- SCD. (2018). Sudden Cardiac Death Holter Database. Retrieved January 8, 2019, from: <https://physionet.org/physiobank/database/sddb/#clinical-information/databased>.
- Wang, B. (2005). Detection Of Structural Damage Using Fractal Dimension Technique. *Journal of Vibration and Shock*, 24, 87–88.

Anexos.

Anexo A: Código de la lectura de las señales ECG y su análisis

```
clear all; close all;clc;
for k=1:20

S = sprintf('%dm.mat',k);
load(S); %%Senal a leer
Fs = 250;
ND = length(se);
t = 0:1/Fs:(ND-1)/Fs;
TS = 14; %%Minutos antes del infarto
NTS = 60*TS;
switch lower(S)
    case '1m.mat'
        NF = 28473;
        NI = 28473 - NTS;
    case '2m.mat'
        NF = 49344;
        NI = 49344 - NTS;
    case '3m.mat'
        NF = 60318;
        NI = 60318 - NTS;
    case '4m.mat'
        NF = 17179;
        NI = 17179 - NTS;
    case '5m.mat'
        NF = 23744;
        NI = 23744 - NTS;
    case '6m.mat'
        NF = 88496;
        NI = 88496 - NTS;
    case '7m.mat'
        NF = 68341;
        NI = 68341 - NTS;
    case '8m.mat'
        NF = 5473;
        NI = 5473 - NTS;
    case '9m.mat'
        NF = 28914;
        NI = 28914 - NTS;
    case '10m.mat'
        NF = 16671;
        NI = 16671 - NTS;
    case '11m.mat'
        NF = 10764;
        NI = 10764 - NTS;
```

```

case '12m.mat'
    NF = 56231;
    NI = 56231 - NTS;
case '13m.mat'
    NF = 70725;
    NI = 70725 - NTS;
case '14m.mat'
    NF = 65357;
    NI = 65357 - NTS;
case '15m.mat'
    NF = 13307;
    NI = 13307 - NTS;
case '16m.mat'
    NF = 22381;
    NI = 22381 - NTS;
case '17m.mat'
    NF = 8980;
    NI = 8980 - NTS;
case '18m.mat'
    NF = 42343;
    NI = 42343 - NTS;
case '19m.mat'
    NF = 82703;
    NI = 82703 - NTS;
case '20m.mat'
    NF = 9160;
    NI = 9160 - NTS;
end

%%MAXIMA IDENTIFICATION
SP1 = se(1,NI*Fs:NF*Fs);
NDn = length(SP1);
tn = 0:1/Fs:(NDn-1)/Fs;
% figure,plot(tn,SP1);

ser = resample(SP1,512,1000);
Ndf = length(ser);
tf = 0:1/128:(Ndf-1)/128;
figure,plot(tf,ser)

%FRACTALES
q = 1;
NV = 14; %%CADA UNA DE 1 MUNITO
NDF = floor(length(ser)/NV);
for i=1:NV
    SCD_H_64(k,i) = Higuchi_FD(ser(1,q:NDF*i),64);
    SCD_H_32(k,i) = Higuchi_FD(ser(1,q:NDF*i),32);
    SCD_K(k,i) = katzFractalDimension(ser(1,q:NDF*i));
    SCD_B(k,i) = -BoxCountingFractalDimension(ser(1,q:NDF*i));
    q = q + NDF;
end

```

```
end
save ('SCD_H_64', 'SCD_H_64');
save ('SCD_H_32', 'SCD_H_32');
save ('SCD_K', 'SCD_K');
save ('SCD_B', 'SCD_B');
```

Dirección General de Bibliotecas UAQ

Anexo B: Código entrenamiento y verificación de la red neuronal

```
%ENTRENAMIENTO
clc;clear all;close all;
load TS_S1.mat
load TS_S2.mat

net = newff([1.0 2.0;
            1.0 2.0],[10 2],{'logsig','logsig'},'trainlm');

N = 400;

input=[TS_S1;
       TS_S2];
target(1, 1:N)      = 1; %%SANO
target(2, N+1:N*2) = 1; %%SCD

net = train(net,input,target);

%VALIDACION
clc;clear all;close all;
load NN
load prom_S1
load prom_S2

input = [prom_S1(1:9);
        prom_S2(1:9)];

output=sim(net,input);
figure,plot(output(1,:),'.b');title('SANO');axis([0 10 0 1.1]);
figure,plot(output(2,:),'.b');title('SCD');axis([0 10 0 1.1]);
```