

Sistema IoT para monitoreo de actividad cardiaca con variabilidad de frecuencia para
el diagnóstico de enfermedades cardiovasculares

Carlos Fabian Dovalés Galvis y Karen Dayana Martínez Siado

Trabajo de Grado para Optar al Título de Ingeniero Electrónico

Director

Jaime Guillermo Barrero Pérez

Magister en Ingeniería área electrónica

Universidad Industrial de Santander

Facultad de ingenierías Fisicomecánicas

Escuela de Ingenierías Eléctrica, Electrónica y Telecomunicaciones

Bucaramanga

2021

Dedicatoria

Este trabajo de investigación lo dedico primeramente a Dios por bendecir mi vida, por guiarme a lo largo de mi existencia y permitirme haber llegado hasta este momento tan importante de mi formación profesional.

A mi madre Yolima Martinez Siado, por haberme brindado su inmenso amor, trabajo y sacrificio en todos estos años de mi vida, por darme las fuerzas para seguir adelante, gracias a ella he logrado llegar hasta aquí y convertirme en la mujer que soy hoy. A mi hermano Nicolás Valle Martinez por siempre estar pendiente de mí, por brindarme su amor, apoyo y confianza a lo largo de este proceso de mi vida.

A mi tía Verence Martinez Siado y mi abuela Erita Siado Suarez, quienes han sido para mí como una madre, que con su amor y dedicación me han ayudado a cumplir este sueño tan anhelado.

A Naufal Yacub Jiménez, quien ha sido una persona muy importante en este proceso, por su amor y apoyo brindado en el transcurso de mi carrera profesional.

Karen Martínez Siado

Este proyecto se lo dedico a mis padres, Claudia Galvis y Jairo Dovalés, por su paciencia, apoyo y gran sacrificio a lo largo de mi vida, por los valores inculcados que me permitieron ser mejor persona cada día.

A mi colega a Karen, mi compañera y amiga, la persona con quien realizamos esta investigación, gracias por la paciencia.

A la familia Dovalés Vargas, por brindarme su apoyo en mi formación académica.

A mis colegas y amigos que de alguna u otra forma hicieron parte de este proceso de formación académica, muchas gracias.

A Paola Andrea Suárez, por brindarme su amor, su cariño y su incondicional apoyo durante este proceso de investigación.

Carlos Fabian Dovalés Galvis

Agradecimientos

En el presente proyecto agradecemos a Dios por ser nuestra guía y acompañarnos en el transcurso de nuestras vidas, brindándonos paciencia y sabiduría para culminar con éxito nuestras metas.

A nuestros padres por ser pilares fundamentales de nuestros sueños, por confiar y creer en nuestras expectativas y habernos apoyado incondicionalmente en todo este proceso, pese a las adversidades e inconvenientes que se nos presentaron.

A nuestras Familias por sus oraciones, consejos y apoyo incondicional durante esta carrera universitaria, que hicieron posible uno de nuestros mayores sueños.

Agradecemos a nuestro director de tesis Msc. Jaime Guillermo Barrero Pérez, quien con su experiencia, conocimiento y motivación nos orientó en cada una de las etapas de este trabajo de investigación hasta alcanzar los objetivos propuestos.

Agradecemos también a la Universidad Industrial de Santander por habernos aceptado ser parte de ella, y con sus conocimientos poder llevar a cabo nuestra carrera profesional.

Tabla de contenido

Introducción	15
1. Objetivos.....	19
1.1 Objetivo General.....	19
1.2 Objetivos Específicos	19
2. Marco Teórico	20
2.1 Fisiología del sistema nervioso autónomo.....	20
2.2 Electrocardiografía Básica.....	20
2.2.1 Electrocardiograma.....	20
2.2.2 Sistema de conducción del corazón.....	21
2.2.3 Interpretación del electrocardiograma	22
2.2.4 Derivaciones del ECG	25
2.3 Arritmias y trastornos en la conducción	27
2.4 Transformada Wavelet	29
2.4.1 Definición de la TW	29
2.4.2 Transformada Wavelet Discreta	30
2.5 Análisis Multirresolución	31
2.6 Inteligencia Artificial.....	32
2.7 Aprendizaje Automático.....	32
2.8 Máquinas de soporte Vectorial (SVM).....	33
2.9 Redes Neuronales Artificiales (ANN).....	34
2.9.1 Perceptrón.....	34
2.9.2 Función de activación.....	35
2.10 Regresión Logística	37

3.	Adquisición de datos, diseño del sistema y procesamiento de datos.....	38
3.1	Adquisición de datos	38
3.1.1	Electrodos	38
3.1.2	Monitor de señales cardiacas- AD8232.....	38
3.2	Microcontrolador	40
3.3	Circuitos impresos del prototipo.....	42
3.4	Versión Final del prototipo Impreso.....	43
3.5	Procesamiento de datos	45
3.5.1	Remuestreo	46
3.5.2	Eliminación de línea base	47
3.5.3	Eliminación de Ruido	48
3.5.4	Detección de picos R	49
3.6	Variabilidad de la Frecuencia Cardiaca.....	53
4.	Algoritmos de Aprendizaje y Clasificación.....	57
4.1	Bases de Datos.....	57
4.2	Arquitectura del modelo	60
4.3	Algoritmos de aprendizaje	62
4.3.1	Modelo de Regresión Logística.....	62
4.3.2	Modelo de Maquina de Soporte Vectorial (SVM)	64
4.3.3	Modelo MLP.....	64
5.	Resultados.....	65
5.1	Modelo de Regresión Logística	66
5.2	Modelo de SVM	69
5.3	Modelo MLP.....	73
6.	Comunicación, envío de datos IoT y reporte del diagnóstico.	76

7.	Conclusiones.....	79
8.	Recomendaciones	81
	Referencias Bibliográficas.....	83
	Apéndices	89

Lista de Tablas

Tabla 1. Funciones de activación más utilizadas	36
Tabla 2. Especificaciones de microcontroladores comerciales.....	41
Tabla 3. Resultados de los modelos implementados para la clasificación de las arritmias Taquicardia y Bradicardia en el entorno de Google Colab.....	76

Lista de Figuras

Figura 1. Sistema de conducción del corazón.....	22
Figura 2. Ondas de un Electrocardiograma normal	23
Figura 3. Representación de dos latidos cardíacos consecutivos en el electrocardiograma ...	24
Figura 4. Derivaciones bipolares	26
Figura 5. Ritmo Sinusal o Normal	28
Figura 6. Bradicardia Sinusal.....	28
Figura 7. Taquicardia ventricular.....	29
Figura 8. Sistema global de proceso de una ANN.....	34
Figura 9. Modelo del perceptrón.....	35
Figura 10. Tarjeta del kit de monitoreo de frecuencia cardiaca- AD8232	39
Figura 11. Modulo ESP 32 WROOM.....	42
Figura 12. Arquitectura del integrado AD8232.	42
Figura 13. Esquemático del monitor de ritmo cardiaco.....	43
Figura 14. Esquemático de las placas ESP 32 WROOM y AD8232 en EasyEDA.....	43
Figura 15. Parte inferior de la PCB, conexión del AD8232.	44
Figura 16. Parte superior de PCB, conexión del ESP32.....	44
Figura 17. Sistema completo	45
Figura 18. Diagramas de bloques del proceso	46
Figura 19. Componentes espectrales de la señal cardiaca	46
Figura 20. Onda wavelet biortogonal 6.8	47
Figura 21. Filtros de análisis y síntesis	48
Figura 22. Comparación entre la onda original y la onda sin línea isoelectrica o línea base .	48

Figura 23. Comparación de la señal desde la original hasta último bloque de filtrado	49
Figura 24. Detección de picos R.....	52
Figura 25. Medidas en el dominio de la frecuencia seleccionadas de una VFC.....	54
Figura 26. Tacograma generado por el software Kubios HVR	54
Figura 27. Características en el tiempo extraídas de Kubios HVR	55
Figura 28. Características en frecuencia extraídas de Kubios HVR.....	55
Figura 29. Librerías para el procesamiento de datos	60
Figura 30. Instrucción read csv, para cargar los datos del entrenamiento	61
Figura 31. Distribución de los datos de entrenamiento	61
Figura 32. Instrucción read_csv, para cargar los datos de validación	61
Figura 33. Distribución de los datos de validación.....	61
Figura 34. Datos de entrenamiento separados	62
Figura 35. Datos de validación separados	62
Figura 36. Resumen de la arquitectura del modelo de Regresión Logística.....	63
Figura 37. Aplicación de la técnica cross-validation.....	63
Figura 38. Resumen de la arquitectura del modelo SVM.....	64
Figura 39. Resumen de la arquitectura del modelo MLP	65
Figura 40. Precisión de entrenamiento del modelo de Regresión Logística.....	66
Figura 41. Optimización del parámetro C, para el modelo de RL.....	66
Figura 42. Optimización de C para el modelo de Regresión Logística	66
Figura 43. Predicción del modelo de Regresión Logística	67
Figura 44. Precisión validación del modelo Regresión Logística	67
Figura 45. Matriz de confusión del Modelo de Regresión Logística.....	68
Figura 46. Reporte de clasificación del modelo de Regresión Logística.....	68
Figura 47. AUC del modelo de Regresión Logística.....	68

Figura 48. Gráfica curva ROC Regresión Logística.....	69
Figura 49. Precisión de entrenamiento del modelo SVM.....	70
Figura 50. Optimización de C, en el modelo SVM	70
Figura 51. Precisión en validación del modelo de SVM	71
Figura 52. Matriz de confusión para el modelo SVM	71
Figura 53. Reporte de clasificación del modelo de SVM	71
Figura 54. AUC del modelo SVM.....	72
Figura 55. Curva ROC SVM	72
Figura 56. Precisión de entrenamiento del modelo MLP	73
Figura 57. Optimización del parámetro Alpha del modelo MLP.	73
Figura 58. Precisión de validación en el modelo MLP.....	74
Figura 59. Matriz de confusión para el modelo MLP	74
Figura 60. Resumen de clasificación del modelo MLP	75
Figura 61. AUC del modelo MLP	75
Figura 62. Curva ROC MLP.....	75
Figura 63. Visualización de los botones	77
Figura 64. Canal Electrocardiografía en ThingSpeak.....	78
Figura 65. Solicitud HTTP en formato JSON.....	78
Figura 66. Segmento de la señal ECG de uno de los autores	79
Figura 67. Diagnóstico de uno de los autores de esta investigación.....	79
Figura 68. Anatomía del Corazón.....	89
Figura 69. Arritmia sinusal respiratoria	90
Figura 70. Taquicardia Sinusal	91
Figura 71. Extrasístoles supraventriculares	91
Figura 72. Taquicardia paroxística supraventricular	92

Figura 73. Aleteo auricular	92
Figura 74. Fibrilación Auricular	93
Figura 75. Extrasístole ventricular.....	93
Figura 76. Fibrilación ventricular	94
Figura 77. Diferentes tipos de Bloqueos cardiacos.....	95
Figura 78. Respuesta en frecuencia del monitor cardiaco AD8232	96

Lista de apéndices

Apéndice A. Conceptos básicos utilizados para la elaboración de este proyecto de investigación.	89
Apéndice 2. Respuesta en frecuencia del monitor cardíaco.	96

Resumen

Título: Sistema IoT para monitoreo de actividad cardiaca con variabilidad de frecuencia para el diagnóstico de enfermedades cardiovasculares*

Autor: Carlos Fabian Dovalés Galvis y Karen Dayana Martínez Siado**

Palabras Clave: Electrocardiograma, Variabilidad de la frecuencia cardiaca, Internet de las cosas (IoT)

Descripción: Las enfermedades cardiovasculares han sido uno de los campos de la medicina en los que más se ha avanzado; hoy en día los pronósticos han cambiado y muchos pacientes consiguen recuperarse y vivir con normalidad. Durante los últimos años, los avances sin precedentes logrados en los campos de la biología, la electrónica y la genética humana han permitido desarrollar un nuevo conjunto de instrumentos para proteger y mejorar la salud humana. En el mundo y acorde a las nuevas tecnologías en Informática y comunicación aplicadas a la medicina, diseñadas para plantear soluciones a problemáticas de la salud, se busca trabajar en diversas estrategias que beneficien específicamente el campo de la medicina, buscando sistemas adecuados, aplicables, sostenibles económicamente, con excelentes resultados, teniendo en cuenta la realidad social, económica y capacidad tecnológica.

Por esta razón, este proyecto de investigación implementó un sistema de monitoreo de señal cardiaca de bajo costo, conformado por la placa de adquisición de la señal ECG AD8232, el microcontrolador ESP32 y una plataforma IoT para enviar los datos a la nube.

Para la clasificación de arritmias se implementaron tres modelos de aprendizaje automático, los cuales fueron Regresión Logística, Maquinas de soporte vectorial y una red neuronal Perceptrón Multicapa, los cuales permitieron identificar tres tipos de diagnósticos: bradicardia, taquicardia y ritmo normal, con precisiones de hasta un 98.53 %. El entrenamiento de los modelos se hizo en el entorno gratuito Google Colaboratory. Así mismo, para la optimización del proceso, el sistema posee conectividad a internet (IoT) y una página web, los cuales permiten la visualización del diagnóstico y de un segmento de la señal cardiaca del paciente. Para el envío de los datos y el diagnóstico vía Wifi se utilizó la plataforma Thingspeak.

* Trabajo de Grado

** Facultad de Ingenierías Fisicomecánicas. Escuela de ingeniería eléctrica, electrónica y en telecomunicaciones. Director: Jaime Guillermo Barrero Pérez. Magister en Potencia Eléctrica.

Abstract

Title: IoT system for monitoring cardiac activity with frequency variability for the diagnosis of cardiovascular diseases*

Author(s): Carlos Fabian Dovalés Galvis y Karen Dayana Martínez Siado ¹

Key Words: Electrocardiogram, Heart rate variability, Internet of things (IoT)

Description: Cardiovascular diseases have been one of the fields of medicine in which the most progress has been made; nowadays the prognoses have changed and many patients manage to recover and live normally. During the past few years, unprecedented advances in the fields of biology, electronics and human genetics have led to the development of a new set of instruments to protect and improve human health. In the world and according to the new technologies in Informatics and communication applied to medicine, designed to propose solutions to health problems, it seeks to work on various strategies that specifically benefit the field of medicine, seeking appropriate, applicable, sustainable systems economically, with excellent results, taking into account the social and economic reality and technological capacity.

For this reason, this research project implemented a low-cost cardiac signal monitoring system, made up of the AD8232 ECG signal acquisition board, the ESP32 microcontroller and an IOT platform to send the data to the cloud.

For the classification of arrhythmias, three automatic learning models were implemented, which were Logistic Regression, Vector Support Machines and a Multilayer Perceptron neural network, which allowed the identification of three types of diagnoses: bradycardia, tachycardia and normal rhythm, with precisions of up to 98.53%. The training of the models was done in the free Google Colaboratory environment. Likewise, for the optimization of the process, the system has internet connectivity (IoT) and a web page, which allow the visualization of the diagnosis and a segment of the patient's cardiac signal. To send the data and the diagnosis via Wifi, the Thingspeak platform was used.

* Degree Work

¹Faculty of Psysicomechanical Engineering, School of Electrical, Electronic and Telecommunications Engineering. Director: Jaime Guillermo Barrero Perez. Magister in Electrical Power.

Introducción

En la actualidad, para la ingeniería, la salud ha sido uno de los fundamentos de la investigación aplicada. Desde la prevención, se encuentran elementos tales como el diseño y uso de tecnologías que permiten controlar variables que afectan la salud del ser humano. Según la Organización Mundial de la salud (OMS), las enfermedades cardiovasculares están posicionadas como la principal causa de muerte en el mundo (World Health Organization, 2020). Las recomendaciones y planes estratégicos de la OMS se enfocan en la prevención y detección temprana de estas enfermedades, a través de la disponibilidad de tecnología y medicamentos (World Health Organization, 2020). Por esto, se han desarrollado múltiples sistemas y algoritmos para ayudar a los médicos en la detección y clasificación de anomalías cardíacas, como las arritmias del corazón o enfermedades respiratorias.

En América Latina las enfermedades cardiovasculares son la causa de más de cinco millones de muertes cada año, en las que se destacan como más comunes las enfermedades isquémicas del corazón, cardiopatía hipertensiva, arritmias cardíacas y ataque cerebral (World Health Organization , 2011). Según las estadísticas de la Organización Mundial de la Salud, aproximadamente el 15% de las muertes se deben a arritmias, en todo el mundo. Estos tipos de enfermedades cardiovasculares afectan desproporcionadamente a los individuos de estatus socioeconómico bajo (World Health Organization , 2011). Por eso la preocupación recae no solo en factores de riesgo tradicionales como el colesterol, la hipertensión y la diabetes, sino también en factores sociales y económicos, que son desafíos en la prevención de la enfermedad cardiovascular en Latinoamérica.

Actualmente los pacientes se realizan sus estudios en los centros hospitalarios, muchas veces teniendo que esperar varios meses entre examen y la consulta médica, debido a la gran demanda. Además, asistir a chequeos médicos puede costarle al paciente mucho tiempo y

dinero, lo que hace que prefiera posponerlos o cancelarlos. Todo esto genera complicaciones para las personas que no cuentan con los recursos necesarios para desplazarse a realizar sus chequeos.

Las arritmias cardíacas constituyen un problema relevante por su incidencia y trascendencia clínica. Se requiere la aplicación de importantes esfuerzos para conseguir su control eficaz a través del perfeccionamiento de las técnicas diagnósticas, mediante una prevención efectiva, que impida o dificulte su desencadenamiento. Es ahí, donde se ha generado el diseño de dispositivos electrónicos, portátiles, de fácil manejo y autonomía en su funcionamiento. El uso de estos dispositivos permite conocer y determinar el estado de salud de una persona sin ser hospitalizados, lo que ayuda a mejorar su calidad de vida y minimiza el coste sanitario. Y en caso de existir una anomalía cardíaca contar con una intervención médica inmediata.

La monitorización de la Variabilidad de Frecuencia Cardíaca (VFC) es un método relativamente nuevo para medir el estado de salud del cuerpo humano. Su obtención podría ser una herramienta predictiva temprana o diagnóstica en enfermedades cardiovasculares, brindándole ayuda a los médicos, para diagnosticar más fácilmente estas enfermedades. Existen diversos métodos para medir la variabilidad de la frecuencia cardíaca, la manera habitual de medirla es a partir del electrocardiograma (ECG), donde se detecta cada una de las ondas R y se calcula el tiempo entre las diferentes ondas R consecutivas o intervalo RR (Rodas, Pedret Carballido, Ramos , & Capdevila, 2008). La VFC, puede emplearse como factor predictor en la aparición de eventos coronarios, accidentes cerebrovasculares, arritmias cardíacas, muerte súbita, entre otros.

Por otro lado, la inteligencia artificial, están teniendo en los últimos años un gran desarrollo e impacto en diversas áreas del conocimiento, incluida la medicina (Saenz Bajo, y otros, 2002). Las redes Neuronales, tienen la utilidad para pronosticar la evolución de distintas

patologías, o intervenciones terapéuticas, clasificar y reconocer muestras anatomopatológicas, entre otros (Saenz Bajo, y otros, 2002).

Este proyecto de investigación busca contribuir a la población no solo desde el campo académico, sino también desde el ámbito social y económico, un sistema electrónico portátil, capaz de obtener la señal ECG de una persona, con aplicación en medicina, usando tecnologías de comunicación, con la finalidad de hacer que procedimientos médicos, como el monitoreo de la variabilidad de frecuencia cardíaca de una persona para la detección de arritmias, sean más beneficiosos y asequibles a toda la sociedad. El sistema implementado está basado en la tecnología IoT, cuenta con las medidas necesarias para dar un diagnóstico de si la persona presenta arritmias cardíacas (Taquicardia o Bradicardia) o no, sin necesidad de que este tenga que ir a consulta presencial con un especialista, ya que dichas señales tomadas por el dispositivo serán almacenadas en una nube y tendrá la opción de observarlas en un dispositivo móvil de uso diario, lo que facilitará a la persona y al médico tener acceso a un historial de medidas. Lo cual, dará un indicio del estado de salud de la persona. En la actualidad se encuentran electrocardiógrafos para obtener la señal ECG de una persona, pero no cuentan en su mayoría con la característica de portabilidad y la transmisión de información por internet.

Este dispositivo cuenta con el uso de sensores, para la toma de medidas y con un microcontrolador que cuenta con los requerimientos necesarios para el desarrollo de este proyecto.

Con estas funcionalidades, el sistema está enfocado en mejorar la calidad de vida de una persona y contribuir al estado del arte con el prototipo de un sistema formado por un dispositivo hardware y un componente software. De esta forma, este podría ser distribuido de una forma más eficiente entre las personas afectadas, facilitando así la detección y atención temprana.

Este trabajo está organizado de la siguiente manera, En el segundo capítulo se describen conceptos básicos utilizados en el desarrollo de esta investigación, como principios básicos de electrocardiografía, Inteligencia Artificial, definiciones principales de la Transformada Wavelet y Análisis multirresolución, los cuales fueron utilizados para el procesamiento de los datos; como eliminación de línea base, eliminación de ruido, detección del complejo QRS, etc. El tercer capítulo describe la adquisición y procesamiento de los datos, el capítulo cuatro muestra los modelos de clasificación implementados en este proyecto, en el capítulo quinto se muestran los resultados obtenidos por los modelos implementados, el capítulo sexto describe la comunicación y envío de datos por medio de IoT, utilizando Thingspeak y finalmente en el capítulo séptimo las conclusiones y recomendaciones.

1. Objetivos

1.1 Objetivo General

Implementar un sistema IoT, que permita monitorear la variabilidad de frecuencia cardiaca, para diagnosticar enfermedades cardiovasculares.

1.2 Objetivos Específicos

Implementar un sistema portátil basado en un microcontrolador, que permita adquirir, procesar, almacenar y transmitir la señal cardiaca de una persona.

Diagnosticar arritmias como la taquicardia y la bradicardia por medio el análisis de la señal ECG, la cual puede ser obtenida por el equipo portátil o por medio de una base de datos, aplicando Inteligencia Artificial (IA).

Desarrollar un aplicativo a través de una API, que nos permita almacenar la base de datos y la señal.

2. Marco Teórico

2.1 Fisiología del sistema nervioso autónomo

El sistema nervioso autónomo (SNA) o vegetativo es la parte del sistema nervioso central y periférico que se encarga de la regulación de las funciones involuntarias del organismo, del mantenimiento de la homeostasis interna y de las respuestas de adaptación ante las variaciones del medio externo e interno (Costa Gómez, 2010).

El sistema nervioso autónomo, posee dos ramas fundamentales: El sistema nervioso simpático y el parasimpático. Ambos sistemas son complementarios y suplementarios en muchas funciones inconsistentes del cuerpo y manejan un delicado equilibrio.

El sistema nervioso simpático prepara el cuerpo para situaciones que requieren estado de alerta o fuerza, como situaciones que despiertan temor, ira, emoción o situaciones de lucha o huida. En este tipo de situaciones, el sistema nervioso simpático estimula los músculos cardíacos para aumentar la frecuencia cardíaca, dilata los bronquios de los pulmones, incrementando la retención de oxígeno y causa la dilatación de los vasos sanguíneos que irrigan el corazón y los músculos esqueléticos, aumentando el suministro de sangre.

En contraposición, el sistema nervioso parasimpático o vagal tiene como función la conservación de la energía. Produce cambios encaminados a conservar y restaurar la energía y asegurar el bienestar a largo plazo. Este sistema estimula la producción de enzimas digestivas y estimula los procesos de digestión, micción y defecación. Reduce la presión arterial y las frecuencias cardíaca y respiratoria, y conserva la energía mediante la relajación y el descanso.

La variabilidad de frecuencia cardíaca (VFC) es el resultado de las interacciones entre el Sistema nervioso autónomo, con su equilibrio simpático-vagal y el sistema cardiovascular. (Se explicará más adelante.)

2.2 Electrocardiografía Básica

2.2.1 *Electrocardiograma*

Consiste en registrar la actividad de la corriente eléctrica, que se está desarrollando en el corazón, durante un tiempo determinado (Azcona, 2010). El ECG se ha diseñado para mostrarnos la magnitud y la dirección de las corrientes eléctricas producidas por las estructuras que forman el corazón. Se ha constituido en la herramienta diagnóstica más utilizada para el enfoque inicial de las enfermedades cardiovasculares.

La actividad eléctrica del corazón recogida en el ECG se observa en forma de un trazado que presenta diferentes deflexiones u ondas del ECG, que corresponden con el recorrido de los impulsos eléctricos a través de las diferentes estructuras del corazón.

2.2.2 *Sistema de conducción del corazón*


El corazón tiene un sistema de conducción cardíaco que permite que las células se contraigan y se produzca el ritmo cardíaco. Este sistema está formado por el nodo sinusal, el nodo auriculoventricular y el haz de His (Garcia Rubira, 2010). El sistema funciona de forma parecida al circuito eléctrico de un aparato automático, que en este caso sería el corazón, cuya misión es funcionar ininterrumpidamente, con una fuerza y una frecuencia adecuada a las necesidades del organismo. El nódulo sinusal sería el procesador electrónico que decide cuándo debe contraerse el corazón; lanza un impulso eléctrico que llega a las aurículas y al nódulo auriculoventricular. Este nódulo sería un segundo procesador, que se encarga de controlar que el nódulo sinusal no se haya equivocado, actuando como filtro si vienen más impulsos eléctricos de los necesarios, o envía sus propios impulsos eléctricos si no llega ningún impulso del nódulo sinusal. Los impulsos que salen del nódulo auriculoventricular pasan a una red de conducción que distribuye el impulso eléctrico por los dos ventrículos (Garcia Rubira, 2010).

El paso de esta corriente eléctrica por el corazón se detecta fácilmente mediante el electrocardiograma. Cada una de estas partes del sistema de conducción tiene la propiedad de poder activarse de forma espontánea y provocar la contracción cardíaca; es lo que se llama función de marcapasos (Garcia Rubira, 2010). Cuando el individuo tiene un corazón sano, es

el nodo sinusal el responsable del latido cardíaco, por lo que también se lo conoce como marcapasos fisiológico o normal (Garcia Rubira, 2010). Conforme se avanza a otros elementos del sistema de conducción, la frecuencia de activación es menor, es decir, más lenta. Por tanto, el más rápido es el nodo sinusal, luego el nodo auriculoventricular, posteriormente el haz de His. Cuando el nodo sinusal no funciona correctamente, la responsabilidad del latido cardíaco recae sobre los otros marcapasos, y es el nodo auriculoventricular el siguiente en rapidez (Garcia Rubira, 2010) (Aragoncillo Ballesteros , 2010) . El nodo sinusal hace que el corazón lata entre 60 y 100 veces por minuto; dicho de otra forma, la frecuencia cardíaca normal es de 60 a 100 latidos por minuto. Cuando ésta disminuye por debajo de 60, recibe el nombre de bradicardia; y si aumenta por encima de 100, se denomina taquicardia (Rodriguez Mañero , 2018). Con el ejercicio se produce una taquicardia fisiológica o normal. De la misma forma, durante el sueño o la relajación tiene lugar la bradicardia fisiológica.

Figura 1.

Sistema de conducción del corazón.



Nota: Tomada de (Azcona, 2010)

2.2.3 Interpretación del electrocardiograma

El ECG presenta como línea guía la denominada línea isoelectrónica o línea basal, que puede identificarse fácilmente como la línea horizontal existente entre cada latido. Los latidos cardíacos quedan representados en el ECG normal por las diferentes oscilaciones de la línea


basal en forma de ángulos, segmentos, ondas e intervalos, constituyendo una imagen característica que se repite con una frecuencia regular (Azcona, 2010).

En un ECG normal, cada complejo consta de una serie de deflexiones que alternan con la línea basal. Realizando la lectura de izquierda a derecha, se distinguen la onda P, el segmento P-R, el complejo QRS, el segmento ST y finalmente la onda T. La figura 2 y 3, nos muestra los distintos latidos producidos por la señal ECG normal y los latidos cardiacos consecutivos de un electrocardiograma, respectivamente.

El recorrido en sentido horizontal hace referencia al tiempo transcurrido, y la distancia en sentido vertical al voltaje que se está produciendo.

Figura 2.


Ondas de un Electrocardiograma normal



Nota: Tomada de (Ciencias de la Salud, 2009)

Figura 3.

Representación de dos latidos cardíacos consecutivos en el electrocardiograma



Nota: Tomada de (Azcona, 2010).

Onda P: Es la primera onda hacia arriba que aparece en el ECG. Representa la activación de las aurículas. La primera parte de la onda P representa la activación de la aurícula derecha, la sección media representa la parte final de la activación auricular derecha y el inicio de la activación auricular izquierda y, por último, la porción final representa la culminación de la activación auricular izquierda. Representa el momento en que las aurículas se están contrayendo y enviando sangre hacia los ventrículos.

Segmento PR: Es el tramo de la línea basal que se encuentra entre el final de la onda P y el comienzo del complejo QRS, que puede ser hacia arriba (positiva) o hacia abajo (negativa) del ECG. Durante este período, las aurículas terminan de vaciarse y se produce una relativa desaceleración en la transmisión de la corriente eléctrica a través del corazón, justo antes del inicio de la contracción de los ventrículos.

Complejo QRS: Corresponde con el momento en que los ventrículos se contraen y expulsan su contenido sanguíneo. Como su nombre indica, consta de las ondas Q, R y S. La onda Q no siempre está presente. Por convención, toda onda negativa al comienzo del complejo QRS es llamada onda Q. La primera onda positiva que presenta un complejo QRS es llamada onda R (exista o no la onda Q). Una onda negativa que siga a una onda R es llamada onda S.

Segmento ST: Es el trazado de la línea basal que se encuentra entre el final de la onda S y el comienzo de la onda T. Su elevación o descenso en relación con la línea basal puede significar insuficiencia en el riego del corazón. El sitio de unión entre el complejo QRS y el segmento ST se conoce con el nombre de Punto J (Junction point). Este punto se utiliza para determinar si el segmento ST está elevado o deprimido con respecto a la línea de base del ECG.

Onda T: Es la onda del ciclo cardíaco que representa la repolarización de los ventrículos. Es una deflexión normalmente positiva, es decir por encima de la línea basal. La onda T representa el momento en que el corazón se encuentra en un período de relajación, una vez que ha expulsado la sangre que se hallaba en los ventrículos.

2.2.4 Derivaciones del ECG

La formación del impulso eléctrico del corazón y su conducción por el sistema, son movimientos que generan corrientes eléctricas de muy bajo voltaje, en el orden de los milivoltios, que se pueden registrar al colocar electrodos en sitios apropiados del cuerpo; derivaciones, los cuales, al ser conectados a un instrumento de registro, como el electrocardiógrafo, hacen que se obtenga un trazado que es denominado electrocardiograma (Muñoz, 2009).

El electrocardiograma consta de 12 derivaciones, que son el resultado de la exploración indirecta del corazón desde distintos planos; 3 de ellas son bipolares y se conocen con los nombres de DI, DII y DIII; las otras 9 son unipolares y se denominan por el orden en que se toman, VR, VL y VF, V1, V2, V3, V4, V5 y V6 (Vedado, 2010).


En este proyecto se utilizaron las derivaciones bipolares, específicamente la derivación DI, a continuación, se describe un poco de ella.

Derivaciones bipolares: Son las derivaciones cardiacas clásicas del electrocardiograma descritas por Einthoven. En una derivación bipolar de las extremidades se

coloca un electrodo positivo en una extremidad y uno negativo en otra, midiendo la diferencia de potencial entre ambos.

Figura 4.

Derivaciones bipolares



Nota: Tomada de (Meneses Arévalo & Toloza Cano, 2008)

DI: Diferencia de potencial entre brazo derecho y brazo izquierdo. Su vector está en dirección a 0° .

DII: Diferencia de potencial entre brazo derecho y pierna izquierda. Su vector está en dirección a 60° .

DIII: Diferencia de potencial entre brazo izquierdo y pierna izquierda. Su vector está en dirección a 120° .

Las tres derivaciones bipolares forman en conjunto el triángulo de Einthoven. Estas derivaciones guardan una proporción matemática, basada en la ley de Einthoven, como se muestra en la ecuación 1 (Robledo Carmona, Jiménez Navarro, & Robledo Carmona, 2007).

Ecuación 1

Ley de Einthoven

$$DII = DI + DIII \quad (1)$$

Esta ley es de gran utilidad cuando se interpreta un electrocardiograma, ya que permite determinar si los electrodos han sido bien colocados. Si se varia la posición de un electrodo, esta ley no se cumpliría.

En el anexo 1 se muestran un poco más de definiciones acerca del corazón.

2.3 Arritmias y trastornos en la conducción

En el corazón humano normal, los latidos se generan en el nodo sinusal (SA) y luego se propagan hacia aurículas y ventrículos, como se describió anteriormente. El ritmo de referencia fisiológico del corazón se denomina ritmo sinusal normal, el cual se caracteriza por una frecuencia cardíaca de entre 60 y 100 latidos por minuto (lpm), ondas P con una morfología que indica que se originan en el nódulo sinusal, intervalos PR iguales en todos los latidos y debe haber una onda P por cada complejo QRS (Sgarlatta, 2016).

El ritmo cardíaco puede verse alterado cuando la frecuencia cardíaca es mayor o menor de la normal, cuando el latido se genera en lugares distintos al nodo SA o cuando hay trastornos en la conducción que impiden que el impulso eléctrico se propague de manera correcta. Cualquier alteración en la frecuencia cardiaca o del ritmo cardiaco se denomina arritmia. Entre las arritmias más usuales están las de los grupos de Arritmias con ritmo sinusal, las cuales son: Arritmia sinusal, Bradicardia sinusal y taquicardia sinusal, en el grupo de arritmias Supraventriculares se encuentran: Extrasístoles supraventriculares, Taquicardia paroxística supraventricular, aleteo Auricular y fibrilación Auricular, las del grupo de Arritmias Ventriculares se encuentran: Taquicardia ventricular y fibrilación ventricular y por ultimo los Bloqueos.

De todo este grupo de arritmias, en este proyecto nos enfocamos en las arritmias Bradicardia sinusal, taquicardia ventricular y Ritmo Normal. En esta sección hablaremos un poco de estas arritmias y en el anexo 6 se definen de manera corta cada una de las demás arritmias anteriormente mencionadas.

Ritmo Sinusal o Normal: Los pacientes con este tipo de ritmo, presentan una frecuencia cardiaca regular entre 60 y 100 lpm. Además, para que el ritmo se identifique como normal se debe distinguir con claridad la onda P en el registro del ECG, la cual es una onda

pequeña de bajo voltaje y su aparición es antes del complejo QRS (Zavala Villeda, 2017). En la figura 5 se puede observar un Ritmo Normal.

Figura 5.

Ritmo Sinusal o Normal



Nota: Tomada de (Hakim Vista, 2017)

Bradicardia sinusal: Es una alteración de la frecuencia del impulso eléctrico del corazón producido por el nodo sinoauricular que lleva a que el ritmo de contracción este por debajo de lo normal, es decir, por debajo de 60 latidos por minuto; Ver figura 6.

Figura 6.


Bradicardia Sinusal



Nota: Tomada de (Negrete Salcedo & Hoyos Usta, 2015)

Taquicardia ventricular: Es el hallazgo de más de tres extrasístoles ventriculares consecutivas, a una frecuencia mayor a 120 (Ver figura 7).

En el anexo 1, se puede ver un poco más a detalle las definiciones de las arritmias anteriormente mencionadas.

Figura 7.*Taquicardia ventricular*

Nota: Tomada de (Baquero Alonso, Rodríguez Martín, González Carnero, Gómez Santana, & de Haro Muñoz, 2010).

En el anexo 1, se puede ver un poco más a detalle las definiciones de las arritmias anteriormente mencionadas.

2.4 Transformada Wavelet

Las Wavelets y el análisis multirresolución, constituyen una importante herramienta para abordar problemas fundamentales en el tratamiento de señales que presentan un comportamiento no estacionario, como es el caso de las señales ECG. Entre estos problemas se encuentra, la reducción del ruido, en la detección de determinados patrones o irregularidades en ciertos tipos de señales, como los electrocardiogramas, vibraciones de motores, etc.

La Transformada Wavelet (TW), discrimina la información de la señal en el dominio del tiempo-frecuencia, permitiendo evidenciar asociaciones entre características particulares de la señal en el tiempo y sus componentes en frecuencia; por lo que su utilización en el estudio de señales ECG presenta ventajas significativas, respecto al uso de la Transformada de Fourier (TF) (Sanchez Fuentes & Montero Parra, 2007).

2.4.1 Definición de la TW

La transformada Wavelet es la descomposición de una señal como una combinación de funciones base. Dicha descomposición se obtiene, mediante la dilatación (a) y traslación (b) de un prototipo de onda, llamada Wavelet Madre $\psi(t)$ (Sanchez Fuentes & Montero Parra, 2007).

De esta forma, la expresión matemática que define la transformada Wavelet de una señal $x(t)$ es:

Ecuación 2

Definición de la Transformada Wavelet

$$W_a x(b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt, \quad a > 0 \quad (2)$$

La onda $\psi(t)$, es una señal de duración limitada, cuyo valor medio es cero, de forma predominante irregular y asimétrica. Los coeficientes de la TW de $f(t)$ en la escala a para todos los desplazamientos b , se denotan como $W_a(t)$ (Riberos Sanabria, 2012).

El factor de escala se relaciona con la frecuencia en el dominio transformado, de tal forma que cuanto mayor sea el factor de escala, los coeficientes $W_a(b)$ contienen información de componentes de menor frecuencia de la señal $f(t)$. En tanto que el factor de traslación se relaciona con el tiempo, y hará referencia a el sector de la señal $f(t)$ en el análisis.

En el procesamiento de señales digitales, se emplea generalmente una particularización de la Transformada Wavelet, llamada *Transformada Wavelet diádica* (Mallat & Hwang, Singularity detection and processing with wavelets, 1992), que consiste en la asignación de valores discretos a los parámetros de escala y desplazamiento de la forma $a = 2^j$ y $b = 2^j l$. Así, la Wavelet diádica se define por la expresión que se muestra en la ecuación 3 (Mallat & Hwang, Singularity detection and processing with wavelets, 1992).

Ecuación 3

Definición de la Transformada Wavelet Diádica.

$$\psi_{j,l}(t) = 2^{-\frac{j}{2}} \psi(2^{-j}t - l); \quad j, l \in \mathbb{Z}^+ \quad (3)$$

2.4.2 Transformada Wavelet Discreta

La TW, tiene la finalidad de filtrar gran variedad de señales para su transmisión y estudio. La mayor parte de las señales de interés que será necesario manejar, se almacenan en

formato digital, el cual es más eficiente y manejable. En caso de ser señales captadas directamente del entorno, lo más frecuente es que, antes de pasar a la etapa de procesamiento, las señales sean procesadas, muestreadas y digitalizadas (Blasco Vadillo, 2018).

Para aplicar la transformación Wavelet a señales discretas, nace la Transformada Wavelet Discreta (TWD) y se expresa de la forma como se observa en la ecuación 4 (Blasco Vadillo, 2018).

Ecuación 4

Definición de la transformada Wavelet Discreta.

$$W_j f[n] = \sum_{n \in \mathbb{N}} f[n] \psi_{j,k}[n] \quad (4)$$

Donde, $W_j f[n]$, representa los coeficientes de la TWD y la función $\psi_{j,k}[n]$ corresponde a la función Wavelet en tiempo discreto, donde esta última se expresa así:

Ecuación 5

Representación de los coeficientes de la TWD

$$\psi_{j,k}[n] = 2^{-\frac{j}{2}} \psi(2^{-j}n - k), \quad j, k \in \mathbb{Z}^+ \quad (5)$$

2.5 Análisis Multirresolución

Es la cantidad de detalle que puede observarse en una imagen, y es asociado comúnmente con el concepto de calidad visual. Digitalmente se relaciona con el número de puntos con que se cuenta para la representación de una imagen.

El análisis multirresolución es propuesto por Mallat, el cual consiste en aplicar sucesivamente a la señal un conjunto de filtros pasa altas y pasa bajas, de respuesta al impulso finita, es decir, tipo FIR; con el propósito de diferenciar entre sus componentes de detalle y aproximación a escalas determinadas (Sanchez Fuentes & Montero Parra, 2007). De manera análoga es posible reconstruir la señal original a partir de dichos componentes.

El algoritmo de Mallat utiliza un único par de filtros ortogonales en todas las etapas del proceso de descomposición, permitiendo obtener filtros de espejo en cuadratura para la realización del proceso inverso.

El cálculo de la TWD diádica de una función $f[n]$, mediante el algoritmo de Mallat (Mallat, Zero-crossings of a wavelet transform, 1991), procede según la siguiente regla:

Ecuación 6

Representación de los coeficientes de suavizado

$$S_j f[n] = \sum_{k \in \mathbb{Z}} h_k S_{j-1} f[n - 2^{j-1} k] \quad (6)$$

Ecuación 7

Representación de los coeficientes Wavelet de la TWD

$$W_j f[n] = \sum_{k \in \mathbb{Z}} g_k S_{j-1} f[n - 2^{j-1} k] \quad (7)$$

Donde $S_j f[n]$ representa los coeficientes de suavizado o aproximación y $W_j f[n]$ representa los coeficientes Wavelet o de detalle de la TWD.

2.6 Inteligencia Artificial

La Inteligencia Artificial (IA) es la combinación de algoritmos planteados, con el propósito de automatizar tareas intelectuales, normalmente realizadas por humanos. La IA es un campo general que contiene al Aprendizaje Automático (AA) y al Aprendizaje Profundo (AP).

2.7 Aprendizaje Automático

El aprendizaje automático, también conocido como Machine Learning, es una rama de la IA que se centra en desarrollar sistemas que aprenden o mejoran el rendimiento, en función de los datos que reciben por entrada. Esto se realiza con diversos métodos de aprendizajes, tales como:

Arboles de decisión

Redes neuronales

Redes Bayesianas

Máquinas de vectores de soporte

Análisis de regresión

En la literatura se han encontrado cuatro algoritmos más populares para la clasificación de latidos cardíacos de arritmias, los cuales son: Maquinas de soporte Vectorial (SVM) (Gove & Faytong, 2012), Redes Neuronales Artificiales (ANN) (Mao & Wang, 2012), Discriminante Lineal (LD) (Ferreira Rodriguez & Monteiro Filho, 2019) y Regresión Logística (Urso & Rizzo, 2019).

En esta sección se describen los 3 modelos de clasificación utilizados en esta investigación, los cuales son: Maquinas de Soporte Vectorial, Redes Neuronales (Perceptrón Multicapa) y Regresión Logística.

2.8 Máquinas de soporte Vectorial (SVM)

Las máquinas de soporte vectorial son un conjunto de métodos de aprendizaje supervisado relacionados, que son populares para realizar análisis de clasificación y regresión mediante el análisis de datos y el reconocimiento de patrones (Gove & Faytong, 2012).

Más formalmente, una SVM construye un hiperplano o conjunto de hiperplanos en un espacio de dimensionalidad muy alta o incluso infinita para clasificar todas las entradas, es decir, identifica el hiperplano que separa las diferentes clases, de modo que la distancia inducida entre el hiperplano y los patrones de entrenamiento sea máxima.

Para problemas donde las clases no son separables linealmente, SVM usa una transformación implícita de variables de entrada usando una función de Kernel, que permite a SVM separar vectores de soporte separables no linealmente usando un hiperplano lineal (Gove & Faytong, 2012).


Según Luz et al. (da S. Luz, Robson Schwartz, Cámara Chávez, & Menotti, 2016), este algoritmo de aprendizaje supervisado es uno de los más utilizados en la clasificación de arritmias basados en ECG.

2.9 Redes Neuronales Artificiales (ANN)

Son un campo muy importante dentro de la Inteligencia Artificial. Están formadas por unidades básicas llamadas neuronas, que se conectan entre sí, formando la red neuronal. El objetivo de estos algoritmos es entender datos del mundo real, como imágenes, textos, voz, etc., procesarlos y clasificarlos o etiquetarlos.

Figura 8.

Sistema global de proceso de una ANN.



Nota: Tomada de (Larrañaga, Inza, & Moujahid, 2018).

2.9.1 Perceptrón

El perceptrón es la forma más simple de una red neuronal usada para la clasificación de un tipo especial de patrones, los linealmente separables. El funcionamiento del perceptrón es muy sencillo, simplemente lee los valores de entrada $x_1, x_2, x_3, \dots, x_n$, suma todas las entradas de acuerdo con unos pesos, $w_1, w_2, w_3, \dots, w_n$ y el resultado lo introduce en una función de activación que genera el resultado final, como se puede observar en la figura 9.

El entrenamiento del perceptrón determina los pesos sinápticos y el umbral que mejor hagan que la entrada se ajuste a la salida. Este umbral al final se cambia añadiendo un sesgo (b) al perceptrón. El proceso comienza con valores aleatorios y se van modificando estos

valores según la diferencia entre los valores deseados y los calculados por la red. La salida se puede escribir como vemos en las ecuaciones 8 y 9 (Mao & Wang, 2012).

Ecuación 8

Sumatoria donde se suman todas las entradas del perceptrón

$$z = \sum_{i=1}^n w_i * x_i + b \quad (8)$$


Ecuación 9

Función de activación

$$f(z) = \begin{cases} 0, & z < 0 \\ 1, & z \geq 0 \end{cases} \quad (9)$$

Figura 9.

Modelo del perceptrón.



Nota: Tomada de (Educba, 2019)

Perceptrón multicapa (MLP): El perceptrón multicapa es el tipo de red neuronal artificial (ANN) más utilizado, este tipo de redes neuronales son modelos computacionales usados para la aproximación de características desconocidas, la arquitectura es de un modelo que su alimentación es hacia adelante.




2.9.2 Función de activación

La función de activación se encarga de devolver una salida a partir de un valor de entrada, normalmente el conjunto de valores de salida en un rango determinado como (0,1) o (-1,1).

Se buscan funciones que las derivadas sean simples, para minimizar con ello el coste computacional de su aprendizaje. En la tabla 1 se puede observar las más comunes:

Tabla 1.

Funciones de activación más utilizadas

Función	Gráfica
Escalón $f(z) = \begin{cases} 0, & z < 0 \\ 1, & z \geq 0 \end{cases}$	
ReLU $f(x) = \max(x, 0)$	
Sigmoide $f(x) = \frac{1}{1+e^{-x}}$	

Una de la función de activación más utilizada que no se presenta en la tabla 1, es la función softmax, cuya salida corresponde a una distribución de probabilidad sobre K posibles salidas, donde z es el valor de la red antes de pasar por la función de activación. Se representa matemáticamente así:

Ecuación 10

Representación matemática función activación Softmax.

$$F(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}, \quad j = 1, \dots, K \quad (10)$$

En este proyecto se utilizaron las funciones de activación sigmoide y ReLU.

2.10 Regresión Logística

La regresión logística es uno de los algoritmos de clasificación más comunes y útiles en el aprendizaje automático, utilizado para modelar una variable de resultado categórica (Urso & Rizzo, 2019). Las variables categóricas pueden ser variables de decisión binarias, como, Si/No, Presente/Ausente, Saludable/ Enfermedad, o variables con más de dos niveles, como, causa de muerte: cáncer, enfermedad cardíaca, entre otras. Si la variable de respuesta es binaria, se configurará una regresión logística binaria (BLR); también llamada binomial. Si la variable de respuesta tiene más de dos niveles, se realizaría una regresión logística multinomial (MLR).

Regresión Logística Binomial (BLR): Se usa cuando la variable dependiente es una variable binaria, es decir, de sólo dos categorías, por ejemplo, presencia (Valor 1) o ausencia (Valor 0), de una especie en cualquier sitio.

Regresión Logística Multinomial (MLR): es una estadística de clasificación semiparamétrica que generaliza la regresión logística a problemas multiclase, es decir, que la variable dependiente no está restringida a dos categorías.

La función logística es también llamada función Sigmoide. Esta función es una curva en forma de S que puede tomar cualquier número de valor real y asignar a un valor entre 0 y 1. La función sigmoide matemáticamente se representa como:

Ecuación 11

Representación Matemática de la función sigmoide.

$$f(x) = \frac{1}{1+e^{-(x)}} \quad (11)$$

3. Adquisición de datos, diseño del sistema y procesamiento de datos.

En este capítulo se dará a conocer el proceso de adquisición de la señal electrocardiográfica, los criterios utilizados en la selección de los componentes para el desarrollo del proyecto en la parte de hardware, Las herramientas de software utilizadas para el análisis y procesamiento de los datos.

Para la implementación en hardware, se realizaron comparaciones entre diversos componentes para seleccionar el más adecuado para esta investigación.

3.1 Adquisición de datos

3.1.1 *Electrodos*

Para medir las señales electrocardiográficas de una persona, se le instalarán electrodos en ubicaciones específicas, que en nuestro proyecto se utilizó para la ubicación, la derivación bipolar, la cual consta de 3 derivaciones (I, II, III), como se mencionó anteriormente, en nuestro proyecto se utilizó la derivación DI. Dichos electrodos censarán la actividad eléctrica del corazón, a través de ellos se adquiere la información eléctrica del corazón para la impresión y el análisis del Electrocardiograma.

3.1.2 *Monitor de señales cardiacas- AD8232*

De las partes más importantes de este proyecto se encuentra el sistema que se encargará de la adquisición de la señal cardiaca. Para esto se empleó el kit de monitoreo de frecuencia cardiaca de la empresa SparkFun, denominada *Single Lead Heart Rate Monitor - AD8232*. Este kit posee todo lo necesario para la detección de las señales y su bajo consumo corriente y precio lo hacen un dispositivo rentable. Se trata de una placa que permite medir la actividad eléctrica del corazón. Está basada en el chip AD8232 elaborado por Analog Devices, este es un bloque que permite el acondicionamiento de las señales biopotenciales y está diseñado para la extracción, amplificación y filtrado de señales de baja amplitud en presencia de condiciones

ruidosas, como es el caso de las señales ECG (Devices, Analog). Uno de los beneficios que nos ofrece este dispositivo, es la conexión de un ADC para la digitalización de la señal de salida, generada por el AD8232.

Tensión de alimentación: 2[V] a 3.5[V]

Consumo de corriente: 170[uA]

Ancho de banda: 0.5[Hz] y 40[Hz]

La respuesta en frecuencia del monitor cardiaco se puede observar en el anexo 2, figura 78.

Figura 10.

Tarjeta del kit de monitoreo de frecuencia cardiaca- AD8232



Nota: Imagen tomada de la hoja de SparkFun. (SparkFun)

Como se observa en la figura 10, la placa cuenta con un conector de 3.5 mm para el cable con los electrodos. Requiere una tensión de alimentación de entre 2 y 3.5 V (la tensión recomendada es de 3.3 V), cuenta con un LED indicador de la frecuencia cardíaca y seis pines: dos para la alimentación, uno para la salida analógica, dos para la detección de desconexión de los electrodos y uno para colocar el chip en modo stand-by, de bajo consumo de corriente. Para este proyecto se utilizaron los primeros cinco pines.

En las figuras 12 y 13 se muestra la arquitectura del integrado AD8232 y el esquemático del monitor de ritmo cardiaco, respectivamente.

3.2 Microcontrolador

Los microcontroladores son dispositivos de circuitos integrados que se utilizan para controlar otras partes de un sistema electrónico, generalmente a través de una unidad de microprocesador, memoria y algunos periféricos. Son usados en muchos procesos industriales debido a su costo reducido, velocidad adaptable y bajo consumo. (Pérez, 2007). Estas características lo convierten en un dispositivo muy importante en el desarrollo de prototipos en el área de Ingeniería electrónica, ya que permiten recibir información de otros dispositivos y realizar acciones de control con los datos que recibe.

Teniendo en cuenta que en este trabajo de investigación era necesario filtrar señales, ejecutar procesos de programación y tener una comunicación vía Wifi con los datos obtenidos, se identificó la necesidad de tener principalmente en cuenta a la hora de la selección del microcontrolador, el bajo costo, la relación entre los parámetros, consumo de potencia, velocidad de procesamiento, tamaño reducido, resolución del ADC y la conexión Wifi.

En la industria electrónica, existen muchas referencias que podrían cumplir estas condiciones, pero para este proyecto se empleó la ESP 32 WROOM, la cual es un módulo basado en unidad de microcontrolador (MCU) genérico y potente que se implementa en diversas aplicaciones que van desde redes de sensores de baja potencia hasta tareas más exigentes. (ESPRESSIF, 2021). Se decidió emplear para este proyecto la ESP32 WROOM, ya que, comparando este microcontrolador con microcontroladores como la Raspberry y el Arduino, tiene menor costo, menor consumo, menor tamaño y contiene conexión Wifi, lo cual es una de las características que nos permite la conexión de nuestro sistema a internet (IoT), cumpliendo uno de los objetivos propuestos en esta investigación.

Tabla 2.*Especificaciones de microcontroladores comerciales.*

MICROCONTROLADORES			
CARACTERISTICAS	ESP WROOM 32	Arduino MEGA 2560	Raspberry Pi 3 B+
Procesador	Xtensa, dual core 32 bits/240 [MHz]	ATmega2560/ @16[MHz]	Broadcom BCM2837B0, Cortex-A53 (ARMv8) 64-bit SoC @ 1.4 [GHz]
RAM	520[kB]	8[kB]	1 [GB]
FLASH	16[MB]	256[kB]	X
CONSUMO	3[V]/80[mA] DC	7V-12V	5[V]/2,5[A] DC
MODULO WIFI	✓	X	X
BLUETOOTH	✓	X	X
TAMAÑO	18[mm]x25,5[mm]	101,52[mm]x53,3[m m]	86[mm]x54[mm]
ACD	12 bits/ 18 canales	10 bits / 16 canales	X
PRECIO	\$ 44.000	\$ 187.000,00	\$ 199.900

En la tabla 2 se exponen las diferentes características a nivel de hardware de cada uno de los microcontroladores disponibles, estos microcontroladores son los más comunes en el mercado, principalmente en enfoques de proyectos en electrónica.

Figura 11.*Modulo ESP 32 WROOM*


Nota: Tomado de: (Electronics, s.f.)

El código implementado en el microcontrolador se desarrolló en el IDE de Arduino. Esta interfaz es compatible con diferentes MCU como lo son las diferentes tarjetas de ESP, el código implementado se encuentra en este [repositorio](#) con el nombre [ECG.ino](#). El código permite la adquisición, transmisión y envío de diagnóstico por WiFi.

3.3 Circuitos impresos del prototipo

El prototipo está compuesto por dos placas, la primera placa es la ESP 32 y la segunda placa es la AD8232, los cuales conforman el sistema final de nuestro proyecto. Este diseño fue elaborado en el software online libre EasyEDA.


En la figura 14 se puede observar el sistema conformado por las dos placas.

Figura 12.*Arquitectura del integrado AD8232.*

Nota: Tomado de la hoja de datos de Analog Devices (Devices, Analog).

Figura 13.


Esquemático del monitor de ritmo cardiaco.



Nota: Imagen tomada de la SparkFun. (SparkFun)

Figura 14.

Esquemático de las placas ESP 32 WROOM y AD8232 en EasyEDA.




3.4 Versión Final del prototipo Impreso

Se muestra el diseño final del sistema, el cual es un electrocardiógrafo, capaz de captar y amplificar la actividad eléctrica del corazón, a través de electrodos. En la figura 17 se muestra el sistema completo.


Figura 15.

Parte inferior de la PCB, conexión del AD8232

**Figura 16.**

Parte superior de PCB, conexión del ESP32



Figura 17.*Sistema completo*


Este dispositivo se alimentará por medio de un *battery pack*, por seguridad eléctrica del dispositivo y del paciente.

3.5 Procesamiento de datos

Después de la señal obtenida por medio del dispositivo, esta señal se transmite por medio del puerto serial vía USB, esta transmisión se programa por medio de una función de Python, estos datos son ingresados a un software adaptado para los fines de este proyecto, el cual fue desarrollado en Matlab (Niño, 2011) y es ejecutado por Python mediante la librería *Matlab Engine*. Este software aplica una serie de procesos en la señal para una mejor visualización. Estos procesos son cuatro:

- Remuestreo
- Eliminación de línea base
- Eliminación Ruido
- Detección del complejo QRS

En la figura 18 se expone mediante un diagrama de bloques el proceso de la señal en cada una de las etapas.


Figura 18.*Diagramas de bloques del proceso*

Las señales electrocardiográficas poseen información relevante entre 1 [Hz] y 150 [Hz], donde se encuentra características propias para los diferentes segmentos de la onda ECG. (Niño, 2011)

- La onda T entre 1 [Hz] y 6 [Hz]
- El complejo QRS entre 5 [Hz] y 15 [Hz]
- La onda P entre 1 [Hz] y 5 [Hz]

3.5.1 Remuestreo

Para evitar perdida de información y encontrar un punto de confianza que se estipule como pico R se debe garantizar una frecuencia mínima de muestreo de 500 [Hz], ya que frecuencias bajas pueden amenazar la validez de los índices en el dominio de la frecuencia de la VFC. (Fred Shaffer, 2017).

Figura 19.*Componentes espectrales de la señal cardíaca*

Nota: Tomado de Carlos niño Página 42 (Niño, 2011)

Este proceso se llevó a cabo dadas las múltiples frecuencias en las que estaban muestreadas las señales empleadas en la base de datos, para esto se implementó un algoritmo

con la función resample, la cual, por medio de la relación entre la frecuencia original y la frecuencia deseada, permite el cambio de velocidad de muestreo en proporción con la original. Esta relación provee un número racional, el numerador y denominador actúan como factores integrales, el primero del aumento del muestreo y el segundo del diezmado.


3.5.2 Eliminación de línea base

Uno de los problemas principales a la hora de procesar las señales cardíacas, son las variaciones de la línea base o línea isoelectrica, estas pueden ser causadas por la respiración del paciente, la cual puede ser representada como una señal sinusoidal con frecuencia igual a la frecuencia de respiración. La variación de la frecuencia puede estar entre 0.15 [Hz] a 0.3 [Hz] (ROMERO, 2015). Otro problema que genera una desviación de la línea base es la electromiografía, la cual va en toda la banda de frecuencia. (Niño, 2011)

Para la eliminación de la línea base se empleó la transformada de Wavelet Biortogonal 6.8, recomendado en Sánchez et (Sanchez Fuentes & Montero Parra, 2007). Para esto se emplea la técnica de análisis en multirresolución, principalmente se plantea llegar al nivel de descomposición 8 con la TW y a partir de este se procede la reconstrucción de la señal sin los componentes espectrales indeseados, como lo plantea Niño. (Niño, 2011).

Figura 20.

Onda wavelet biortogonal 6.8



Nota. Tomado de: (Browser, s.f.)

En la figura 20 se observa la onda wavelet biortogonal 6.8 y en la figura 21 se exponen los filtros de análisis y síntesis de la transformada wavelet.

Figura 21.

Filtros de análisis y síntesis





Figura 22.

Comparación entre la onda original y la onda sin línea isoelectrica o línea base



3.5.3 Eliminación de Ruido

Para el suavizado de la señal, se implementó un filtro promedio móvil de orden 8. El orden del filtro se determinó con base a varias pruebas con distintos filtros de orden superior e

inferior, los cuales para orden superior a 8 el complejo QRS se atenúa y la detección de los picos R se vuelve inexacta.

Ecuación 12


Representación Matemática del filtro promedio móvil de grado 8

$$y[n] = \sum_{m=1}^8 x[n - m] \quad (12)$$

La ecuación 12 representa matemáticamente el filtro promedio móvil. En la figura 23 se expone la señal electrocardiográfica en sus diferentes etapas de filtrado.

Figura 23.

Comparación de la señal desde la original hasta último bloque de filtrado



3.5.4 Detección de picos R

La detección automática de las ondas ECG es una parte muy importante en el diagnóstico de arritmias cardiacas. Un buen resultado para este diagnóstico depende principalmente de una detección confiable y exacta del complejo QRS, así como de las ondas P y T. La detección del complejo QRS es la tarea más importante en el análisis automatizado de señales ECG, ya que una vez éste se detecte, se puede realizar un análisis más detallado de la onda, por consiguiente, existe gran variedad de métodos para llevarla a cabo.

La técnica aplicada en esta investigación para la detección del complejo QRS, fue la transformada Wavelet, debido a su capacidad de detección de transitorios de la transformada, su robustez frente al ruido y no estacionariedades.

Entre las Wavelets más utilizadas están: Las derivadas de una Gaussiana, las Splines, Las de Daubechies, las coiflets y las de Morlet.

El método implementado durante el desarrollo de esta investigación se basa en el concepto de la primera derivada para la identificación de puntos máximos de una señal. En este trabajo se optó por utilizar la transformada Wavelet de la familia Spline de orden 2, la cual es especial para la detección de puntos máximos y mínimos de una onda, método recomendado por (Martínez, 2004).

La wavelet cuadrática Spline permite identificar ondas monofásicas que corresponden a un máximo (positivo) o un mínimo (negativo) de la transformada Wavelet Diádica en las diferentes escalas. El margen creciente de la onda corresponde a un mínimo negativo y el margen decreciente a un máximo positivo. Así se tiene que el cruce por cero representa un máximo o mínimo local de la señal, con un retardo de $2^j - 1$ muestras (Li, 1995), la cual es llamada por (Li, 1995), como Línea de modulo máximo.

El éxito de la determinación de las ondas R está basado en la especificación correcta del umbral de distinción de ondas. Martínez y colaboradores (Martínez, 2004) sugieren la selección de un umbral que sea asociado al valor RMS de la señal en cada uno de los niveles de descomposición. Estos umbrales se definen como:

Ecuación 13

Umbral

$$\epsilon_{QRS}^j = RMS(W_{2^j}X_{[n]}) \quad j = 1, 2, 3 \dots$$

(13)

$$\epsilon_{QRS}^4 = 0.5 * RMS(W_{2^4}X_{[n]})$$

El algoritmo implementado para llevar a cabo la detección del complejo QRS, está basado en el algoritmo desarrollado por Li et al (Li, 1995), donde se especifican procesos para poder determinar la onda R sin necesidad de determinar el inicio y el final del complejo QS.

La detección del complejo QRS se lleva a cabo en 4 etapas: La selección de escalas características, la determinación de las líneas de módulos máximos de las ondas R, la eliminación de las líneas de módulos máximos redundantes y la detección del pico de la onda R.

Selección de escalas características

Para establecer el nivel de descomposición donde se va a determinar el complejo QRS, se debe tener en cuenta la frecuencia de muestreo; la cual determina los puntos disponibles para la representación Wavelet de la señal ECG en las diferentes escalas, además se debe tener en cuenta el ancho de banda de los filtros wavelets usados y las características propias de la señal electrocardiográfica.

Determinación de las líneas de módulos máximos

La determinación de las líneas de módulos máximos de las ondas R inicia en la localización de mayor a menor escala de los coeficientes wavelet que superen un umbral ϵ , en el cuarto nivel de descomposición, como se puede ver en la ecuación 13. Después se inicia un proceso iterativo en los niveles inferiores, que pretende identificar en cada una de las escalas $2^j \ j = N - 1 \dots 1$, la localización de los coeficientes Wavelet, teniendo en cuenta la vecindad que estos tengan con respecto a los detectados en el cuarto nivel de AMR, De tal manera que se retiran los coeficientes por debajo del umbral ϵ en cada nivel de descomposición.

Para la correcta identificación de las líneas de módulos máximos, se procede a identificar y eliminar las parejas de puntos máximos y mínimos aislados (puntos que no pueden

formar una pareja con un mínimo o un máximo en una vecindad cercana a la duración de la onda R) o redundantes (Más de una pareja alrededor de la duración normal de una onda R).

Eliminación de líneas de módulos máximos redundantes


Una onda R se caracteriza por una línea de modulo máximo, sin embargo, mediante el análisis de la Transformada Wavelet Discreta de la señal electrocardiográfica, para el complejo QRS puede presentar más de una línea de modulo máximo, ya que este puede contener más de una onda. Las ondas P, Q, S, T, también tienen su representación en forma de líneas de módulos máximos, pero en escalas diferentes a las seleccionadas para la detección de ondas R. Luego de identificar que la onda R es la onda de mayor amplitud del complejo, se puede eliminar de la preselección las líneas de módulos máximos de las otras ondas.

Detección del pico R

Luego de tener identificadas correctamente las líneas de módulos máximos, correspondientes a la onda R, se procede a hallar el cruce por cero en el nivel wavelet 1, el cual corresponde a la localización temporal del pico de la onda R. La detección de los picos R, se puede observar en la figura 24.

Figura 24.

Detección de picos R



Nota. Después de cargar el programa en el microcontrolador, se procede a generar el archivo que contienen los datos de la señal por medio de una función de puerto serial en Python. También se exportó un segmento de la señal para que sea visualizado en la página web.

3.6 Variabilidad de la Frecuencia Cardiac

Con el pasar de los años y el avance en el campo de la medicina, el estudio del ritmo cardíaco ha permitido encontrar la influencia de este en el sistema cardiovascular, analizando sus patrones rítmicos en distintas frecuencias. (Electrophysiology, 1996). Estos análisis parten de las oscilaciones de las componentes del sistema nervioso autónomo (SNA), donde se establece que las altas frecuencias (HF) son causadas por la excitación vagal o sistema parasimpático y las componentes de frecuencia bajas están causadas por las dos ramas del SNA. (Berntson, 1997).

La extracción de características de este tipo de datos depende de la duración de la señal cardíaca. La sociedad Europea de Cardiología y la Sociedad Norteamericana de Ritmo y Electrofisiología establecen como estándar para el análisis en estudios clínicos que los registros de señales cardíacas obtenidos de corta duración (5 minutos) deben ser analizados por métodos en el dominio de la frecuencia y los registros de larga duración (24 horas) por métodos en el dominio del tiempo. (Electrophysiology, 1996).

Para el desarrollo de este proyecto se emplearon registros de corta duración, es decir, de 5 minutos y el software Kubios HVR Estándar versión 3.5 gratuito para la extracción de características, las cuales Kubios las arroja el dominio del tiempo, en frecuencia y geométricas. Este software proporciona un análisis de la variabilidad de la frecuencia cardíaca preciso y detallado para mediciones a corto y largo plazo. Con Kubios se generó un “tacograma” con los intervalos RR y este fue analizado por medio de métodos en el dominio del tiempo y frecuencia.

En la figura 26 se evidencia el tacograma generado por Kubios de los intervalos RR de la señal cardíaca de uno de los autores, sus respectivas características en tiempo y frecuencia en las figuras 27 y 28 respectivamente.

Figura 25.

Medidas en el dominio de la frecuencia seleccionadas de una VFC

Variable	Units	Description	Frequency Range
Analysis of Short-term Recordings (5 min)			
5-min total power	ms^2	The variance of NN intervals over the temporal segment	$\approx 0.4 \text{ Hz}$
VLF	ms^2	Power in VLF range	$\leq 0.04 \text{ Hz}$
LF	ms^2	Power in LF range	$0.04\text{-}0.15 \text{ Hz}$
LF norm	nu	LF power in normalized units $\text{LF}/(\text{total power}-\text{VLF})\times 100$	
HF	ms^2	Power in HF range	$0.15\text{-}0.4 \text{ Hz}$
HF norm	nu	HF power in normalized units $\text{HF}/(\text{total power}-\text{VLF})\times 100$	
LF/HF		Ratio $\text{LF} [\text{ms}^2]/\text{HF} [\text{ms}^2]$	
Analysis of Entire 24 Hours			
Total power	ms^2	Variance of all NN intervals	$\approx 0.4 \text{ Hz}$
ULF	ms^2	Power in the ULF range	$\leq 0.003 \text{ Hz}$
VLF	ms^2	Power in the VLF range	$0.003\text{-}0.04 \text{ Hz}$
LF	ms^2	Power in the LF range	$0.04\text{-}0.15 \text{ Hz}$
HF	ms^2	Power in the HF range	$0.15\text{-}0.4 \text{ Hz}$
α		Slope of the linear interpolation of the spectrum in a log-log scale	$\approx 0.04 \text{ Hz}$

Nota. Adaptado de: (Electrophysiology, 1996)

Figura 26.

Tacograma generado por el software Kubios HVR






Figura 27.*Características en el tiempo extraídas de Kubios HVR***Figura 28.***Características en frecuencia extraídas de Kubios HVR*

Para el análisis de este proyecto se emplearon características como:

Mean RR: Esta característica permite definir en promedio cual es la frecuencia cardiaca del paciente.

SDNN: Desviación estándar de los latidos normales, los latidos ectópicos (latidos del corazón que se original fuera del nodo sinoauricular) se han quitado (Fred Shaffer, 2017). La desviación estándar es la raíz cuadrada de la varianza, lo que matemáticamente es igual a la potencia del espectro, es decir la desviación estándar tiene relación directa con la potencia de

las bandas VLF, HF y la potencia total. (Umetani K, 2011). Los valores de SDNN predicen tanto la morbilidad como la mortalidad. Sobre la base de la monitorización de 24 h, los pacientes con valores de SDNN inferiores a 50 ms se clasifican como no saludables, 50-100 ms han comprometido la salud y más de 100 ms están sanos. (Fred Shaffer, 2017).

RMSSD: Simboliza el cuadrado medio de las diferencias sucesivas entre latidos normales. El RMSSD refleja la varianza de latido a latido en la frecuencia cardiaca, siendo la medida principal en el dominio del tiempo que permite la estimación de los cambios mediados vagalmente. (Fred Shaffer, 2017).

TINN: Se obtiene a partir de métodos geométricos, y consiste en la variabilidad global de los intervalos RR (Luiz Carlos Marques Vanderlei, 2010). Esto se obtiene por medio del histograma de intervalos NN, y se define geoméricamente como la base medida de la distribución vista como un triángulo.

VLF: La banda de muy bajas frecuencia por sus siglas en inglés (VLF) se posiciona en el espectro de la señal (0.003 – 0.04) [Hz] (Fred Shaffer, 2017), y se asocia con la muerte arrítmica, y el trastorno de estrés postraumático.

LF: La banda de bajas frecuencias o LF, se registran en los rangos de frecuencia de 0.04 [Hz] a 0.15 [Hz], como se planteó anteriormente, el comportamiento de las bajas frecuencias depende de las dos ramas del sistema nervioso autónomo, pero también tienen una relación con barorreceptores cuando se está en condiciones de reposo. (Fred Shaffer, 2017).

HF: La banda de altas frecuencias o *high frequency*, se registra entre el intervalo de frecuencias (0.15 – 0.4) [Hz], comúnmente llamada la banda respiratoria, esta refleja la actividad parasimpática del sistema nervioso autónomo, y corresponden a las variaciones de la frecuencia cardiaca en relación con la respiración. (Fred Shaffer, 2017).

Relación HF/LF: se define como la relación entre las altas y bajas frecuencias, teniendo en cuenta lo que se expuso anteriormente, las altas frecuencias HF son generadas por

el comportamiento del sistema parasimpático y las bajas frecuencias LF por el sistema nervioso autónomo, a partir de esta premisa, se puede determinar que dicha relación refleja la dominancia parasimpática.

4. Algoritmos de Aprendizaje y Clasificación

El entorno de desarrollo elegido para entrenar y probar los tres modelos de aprendizaje Automático; Regresión Logística, Maquinas de Soporte Vectorial y Red neuronal Perceptrón Multicapa, fue Google Colab + Google Drive, Este entorno es un servicio en la nube, ofrecido por Google de manera gratuita. Esta herramienta no requiere de una configuración adicional de tu computadora, ya que Google Colab se encuentra en línea. Además, los Notebooks creados pueden ser compartidos y editados en tiempo real por todas las personas del equipo de trabajo y tienes acceso al hardware de Google, tanto en GPU o TPU totalmente gratis.

4.1 Bases de Datos

Para entrenar el sistema se utilizaron bases de datos que presentaban taquicardia, bradicardia y ritmos normales. La base de datos de señales que presentan taquicardias y ritmos normales están conformadas por latidos cardíacos, agrupados en registros de pacientes, los cuales son de libre acceso que permiten la creación de una estandarización para la evaluación de métodos de clasificación automática de arritmias. Esta estandarización fue desarrollada por AAMI y está especificada en ANSI / AAMI EC57: 1998/ (R) 2008 (American National Standard, 2012).

Las medidas recomendadas por AAMI para evaluar los métodos son: Sensibilidad, Predictividad positiva, Tasa de falsos positivos y Precisión general.

Las bases de datos utilizadas para la construcción de instancias para entrenamiento y prueba de los modelos de clasificación fueron: MIT-BIT Malignant Ventricular Ectopy Database (VFDB) (Greenwald, Scott David, 1999), MIT-BIT Normal Sinus Rhythm Database (NSRDB) (Moody, 1999), Creighton University Sustained Ventricular Arrhythmia Database (CUDB) (Nolle, Badura, catlett, Bowser, & Sketch, 1986). Además de estas bases de datos se utilizó el software ECGSYN para generar señales de ECG sintetizadas con frecuencia cardiaca entre 20-55 Hz, generando así un ritmo cardiaco lento o irregular y utilizarlas como señales que presentaban bradicardia. Obteniendo 39 señales que fueron denominadas B1, B2...B39.

A continuación, se describen las bases de datos utilizadas en este trabajo de investigación, presentando el número de registros, frecuencia de muestreo y resolución de cada una.

VFDB: Esta base de datos incluye 22 registros de ECG de media hora de sujetos que experimentaron episodios de taquicardia ventricular sostenida, aleteo y fibrilación ventriculares. Esta muestreada a 250 muestras por segundo. Se puede encontrar más información sobre esta base de datos en (Greenwald, Scott David, 1999)

NSRDB: Esta base de datos incluye 18 registros de ECG a largo plazo de sujetos remitidos al Laboratorio de Arritmias del Hospital Beth Israel de Boston. Se encontró que los sujetos incluidos en esta base de datos no tenían arritmias significativas; incluyen a 5 hombres, de 26 a 45 años, y 13 mujeres, de 20 a 50 años. Esta muestreada a 250 muestras por segundo. Se puede encontrar más información sobre esta base de datos en (Moody, 1999).

CUDB: Esta base de datos incluye 35 registros de ECG de ocho minutos de sujetos que experimentaron episodios de taquicardia ventricular sostenida, aleteo y fibrilación ventriculares. Se digitalizaron a 250 Hz con una resolución de 12 bits en un rango de 10 V. Se puede encontrar más información sobre esta base de datos en (Nolle, Badura, catlett, Bowser, & Sketch, 1986).

Teniendo en cuenta las bases de datos anteriores, se obtuvo una base de datos general en Excel, la cual contiene todos los registros y características de cada paciente de las bases de datos anteriormente mencionadas.

El estándar AAMI no especifica qué pacientes / latidos deben usarse para construir el modelo a clasificar (fase de entrenamiento) y qué pacientes / latidos deben usarse para los métodos de evaluación, es decir, la fase de prueba, que puede generar resultados sesgados. Por ejemplo, de Chazal al. (de Chazal, O'Dwyer, & Reilly, 2004) demostró que el uso de los latidos del corazón del mismo paciente tanto para el entrenamiento como para las pruebas hace que el proceso de evaluación esté sesgado. Por esto se decidió dividir la base de datos general en dos conjuntos; Uno de entrenamiento y otro de prueba, evitando que los latidos de un mismo registro estén presentes en ambos conjuntos para evitar sesgos. Este protocolo de división se denomina en la literatura esquema o paradigma inter- paciente. Quedando los conjuntos así:

Conjunto de entrenamiento: Cu04, Cu05, Cu06, Cu07, Cu08, Cu09, Cu13, Cu14, Cu15, Cu17, Cu18, Cu19, Cu20, Cu21, Cu22, Cu23, Cu24, Cu25, Cu26, Cu27, Cu28, Cu29, Cu30, Cu31, Cu32, Cu33, 16273, 16420, 16483,16539, 19773, 16786, 16795, 17052,17453,18177, 18184, 19088, 19090, 19093, 19140, 19830, 418, 419, 420, 423, 424, 427, 428, 429, 430, 602, 605, 607, 609, 611, 612, 614, 615, B2, B4, B5, B6, B7, B8, B9, B10, B11, B13, B14, B15, B16, B17, B18, B20, B21, B22, B23, B24, B25, B26, B27, B28, B29, B30, B31, B32, B33, B34, B35, B36, B38, B39.

Conjunto de Prueba: Cu01, Cu02, Cu03, Cu10, Cu11, Cu12, Cu13, Cu14, Cu16, 16265, 16272, 421, 422, 425, 610, B1, B3, B12, B19, B37.

Se usó el conjunto de entrenamiento para construir el modelo de clasificación y el conjunto de prueba se reservó para la evaluación. De esta manera se garantizó que el modelo creado no tuviera contacto con los latidos del corazón del conjunto de prueba, es decir, los latidos del conjunto de entrenamiento y el de prueba provienen de diferentes individuos.

Una vez que se ha definido el conjunto de características a partir de los latidos del corazón (Se mostró en el capítulo anterior), se pueden construir modelos a partir de estos datos, utilizando algoritmos de inteligencia artificial, como lo es el aprendizaje automático para la clasificación de latidos cardíacos de arritmias.

En este proyecto se implementaron 3 diferentes estructuras de aprendizaje automático; Un modelo de máquinas de vectores de soporte, un modelo de Regresión Logística y un modelo de Perceptrón Multicapa, las cuales se detallan a continuación.

4.2 Arquitectura del modelo

La librería escogida para la implementación de los modelos fue *Scikit-Learn*. La cual es una librería muy útil para aprendizaje automático, es de código abierto y proporciona una gama de algoritmos de aprendizaje supervisado y no supervisado.

Inicialmente Importamos las librerías necesarias para cargar los algoritmos y procesar los datos.

Figura 29.

Librerías para el procesamiento de datos

```
import pandas as pd
import numpy as np

from sklearn.linear_model import LogisticRegression
from sklearn.neural_network import MLPClassifier
from sklearn.svm import SVC
```

Posteriormente se tiene guardado en la computadora, dos archivos en formato csv, los cuales contienen las características obtenidas de la señal ECG por medio del software Kubios; un archivo que contiene los datos de entrenamiento, llamado `set_train`, y otro archivo que contiene los datos de prueba, llamado `set_test`. Estos archivos se pueden ver en este [repositorio](#). Luego precedemos a leer los archivos utilizando la instrucción `read_csv` de la librería Pandas. Y pasamos a convertir los elementos de estos archivos en objetos tipo `Dataframe`, utilizando el constructor *Dataframe* de la librería Pandas.

Los datos totales se dividieron en un 80% para entrenamiento y el 20% restante para validación del modelo.

Figura 30.

Instrucción read csv, para cargar los datos del entrenamiento

```
# Cargamos los Datos de entranmiento
Datatrain= pd.read_csv('set_train.csv', sep=",")
dataframe=pd.DataFrame(Datatrain)
print(Datatrain)
```

Se utilizaron para entrenamiento 340 datos, distribuidos de la siguiente manera:

Figura 31.

Distribución de los datos de entrenamiento

```
Label
0    268
1     38
2     34
dtype: int64
```

Figura 32.

Instrucción read_csv, para cargar los datos de validación

```
#Cargamos los datos de validación
Datatest= pd.read_csv('set_test.csv', sep=",")
dataframe=pd.DataFrame(Datatest)
print(Datatest)
```

Y para validación se utilizaron 42 datos, distribuidos como se muestra en la figura 33.

Figura 33.

Distribución de los datos de validación

```
Label
0     32
1       5
2       5
dtype: int64
```

Siendo las etiquetas remplazadas por:

0: Paciente Normal

1: Paciente con Taquicardia

2: Paciente con Bradicardia

Los datos tanto de entrenamiento como de validación debemos separarlos, en las entradas y salidas del modelo. Las características corresponden a las entradas, que llamamos X y las salidas corresponden a las etiquetas, que llamamos Y. Quedando como se muestra en la figura 34 y 35.

Figura 34.

Datos de entrenamiento separados

```
X_train=(dataframe[["Mean RR","SDNN","RMSSD","TINN","VLF","LF","HF","LF/HF"]])  
Y_train=(dataframe["Label"])
```

Figura 35.

Datos de validación separados

```
X_test=(dataframe[["Mean RR","SDNN","RMSSD","TINN","VLF","LF","HF","LF/HF"]])  
Y_test=(dataframe["Label"])
```

Luego de tener los datos listos pasamos a desarrollar el clasificador, utilizando los algoritmos de aprendizaje automático.

4.3 Algoritmos de aprendizaje

4.3.1 Modelo de Regresión Logística

Comenzamos usando un modelo de regresión logística y usamos K veces la validación cruzada en cada uno de los modelos implementados para obtener la precisión en el conjunto de datos. La validación cruzada de K fold es un método que se utiliza para evitar el sobreajuste. Esta técnica consiste en tomar los datos de entrada y dividirlos en K subconjuntos de datos, luego se entrena el modelo en todos los subconjuntos, menos uno de los subconjuntos (k-1) y a continuación se evalúa el modelo en el subconjunto que no se ha utilizado para el

entrenamiento. Esto se repite K veces, con un subconjunto diferente reservado para la evaluación, el cual es excluido del entrenamiento cada vez, es decir, k-fold hace K entrenamientos independientes, y el Accuracy final será el promedio de las K accuracies anteriores.

Aquí, nuestros datos de entrenamiento se dividen en 5 partes, el modelo de predicción se genera para las 4 partes y se prueba en la 5ª parte. Esto se hace 5 veces usando diferentes combinaciones de estas partes como conjuntos de entrenamiento y prueba, y eventualmente se usa un promedio de todos estos modelos para obtener la precisión final.

Figura 36.

Resumen de la arquitectura del modelo de Regresión Logística

```
modelo=LogisticRegression(multi_class='multinomial',solver='newton-cg')
modelo.fit(X_train,Y_train)
```

```
LogisticRegression(C=1.0, class_weight=None, dual=False, fit_intercept=True,
                    intercept_scaling=1, l1_ratio=None, max_iter=100,
                    multi_class='multinomial', n_jobs=None, penalty='l2',
                    random_state=None, solver='newton-cg', tol=0.0001, verbose=0,
                    warm_start=False)
```

Figura 37.

Aplicación de la técnica cross-validation

```
from sklearn.model_selection import cross_val_score
from sklearn.model_selection import KFold
kf = KFold(n_splits=5,random_state = 7)
scores = cross_val_score(modelo, X_train, Y_train, cv=kf, scoring="accuracy")
print("metricas cross_validation",scores)
print("Media de cross_validation",scores.mean()*100, "%")
```

Una vez entrenado nuestro modelo de Regresión Logística procedemos a hacerle clasificar nuestro conjunto de datos de validación, en nuestro caso con el archivo llamado X_test, usando la función *predict ()*. El algoritmo se encuentra almacenado en el siguiente [repositorio](#).

4.3.2 Modelo de Maquina de Soporte Vectorial (SVM)

Luego pasamos a implementar el siguiente clasificador; el modelo de Maquina de Soporte Vectorial.

En este modelo se utilizaron los parámetros: Un kernel *linear*, gamma=1 y un valor de C=0.0000001. Este modelo se implementó con diferentes tipos de kernel; *rbf*, *poly* y *linear*. El modelo que arrojó mejores resultados fue el que se implementó con el kernel *linear*.

Una vez entrenado el modelo de SVM, se pudo ver que la precisión del entrenamiento del modelo bajo a un 97.64%, y el porcentaje de validación a un 95.23%.

Figura 38.

Resumen de la arquitectura del modelo SVM

```
modelo=SVC(kernel='linear',random_state=123 ,probability=1,C=0.000001)
modelo.fit(X_train,Y_train)
```

```
SVC(C=1e-06, break_ties=False, cache_size=200, class_weight=None, coef0=0.0,
    decision_function_shape='ovr', degree=3, gamma='scale', kernel='linear',
    max_iter=-1, probability=1, random_state=123, shrinking=True, tol=0.001,
    verbose=False)
```

El algoritmo de Máquina de soporte vectorial implementado se encuentra en el siguiente [repositorio](#).

4.3.3 Modelo MLP

Finalmente pasamos al modelo MLP, elegimos el solucionador *lbfgs*, el cual funciona mejor en conjuntos de datos pequeños. Se usó la función de activación *logistic*, la cual es la misma función *sigmoid*.

Para la arquitectura de la red neuronal, se decidió usar 12 capa oculta, que es el estándar para la mayoría de los problemas de Redes Neuronales. Para la cantidad de unidades ocultas, se intentó hacer esto experimentalmente, se probó con 5, 10, 12, 15 y 20 capas ocultas y finalmente se escogió utilizar 12, ya que con este número de capas ocultas el modelo arrojó mejores resultados. Quedando el modelo como se muestra en la figura 39.

Figura 39.*Resumen de la arquitectura del modelo MLP*

```
modelo = MLPClassifier(solver='lbfgs', random_state=1, activation='logistic',  
                      hidden_layer_sizes=(12,))  
modelo.fit(X_train,Y_train)  
  
MLPClassifier(activation='logistic', alpha=0.0001, batch_size='auto',  
              beta_1=0.9, beta_2=0.999, early_stopping=False, epsilon=1e-08,  
              hidden_layer_sizes=(12,), learning_rate='constant',  
              learning_rate_init=0.001, max_fun=15000, max_iter=200,  
              momentum=0.9, n_iter_no_change=10, nesterovs_momentum=True,  
              power_t=0.5, random_state=1, shuffle=True, solver='lbfgs',  
              tol=0.0001, validation_fraction=0.1, verbose=False,  
              warm_start=False)
```

Luego de entrenar y evaluar el modelo con el conjunto de datos especificado anteriormente, se observa que la precisión está en un 95.59%, siendo este el resultado de entrenamiento menor de los tres modelos implementados. También se obtuvo en la precisión de validación un resultado menor que los otros dos. Ver en capítulo de resultados. Este algoritmo se encuentra almacenado en este [repositorio](#).

5. Resultados

A continuación, se muestran los resultados obtenidos de los entrenamientos y la validación, para cada uno de los modelos de aprendizaje automático que fueron utilizados para la clasificación de arritmias cardíacas.

Con el fin de exponer mejor los resultados se muestra una matriz de confusión que permite revisar como fueron clasificadas las arritmias cardíacas; en la diagonal principal quedaran la cantidad de aciertos y en el resto de la matriz, se muestra la categoría con la que se confundieron los resultados erróneos. Además, también se presenta el reporte de clasificación de cada uno de los modelos.

5.1 Modelo de Regresión Logística

Figura 40.

Precisión de entrenamiento del modelo de Regresión Logística

Media de cross_validation 98.52941176470588 %

Con un valor del parámetro $C=1$, escogiendo el solucionador *Newton-cg* y aplicando la técnica de K-fold Validación al modelo, se obtuvo una precisión para entrenamiento del 98.52% como se puede ver en la imagen capturada de Google Colab; Figura 40.

Optimizamos los parámetros de nuestro modelo. Para la regresión logística, tiene sentido observar el parámetro C , que es el inverso del parámetro de regularización. Cuanto menor sea el valor de C , mayor será la penalización de los coeficientes de nuestra regresión logística.

Figura 41.

Optimización del parámetro C , para el modelo de RL

```
from sklearn.model_selection import GridSearchCV

param_grid = {"C": [ 0.00001 , 0.0001 , 0.001 ,
                    0.01 , 0.1 , 1.0 , 10.0 ,
                    100.0 , 1000.0 ]}

grid = GridSearchCV ( estimator = modelo ,
                    param_grid = param_grid , cv = kf )

grid . fit (X_train , Y_train)
print( grid . best_estimator_ . C )
print( grid . best_score_ * 100 , "%" )
```

Figura 42.

Optimización de C para el modelo de Regresión Logística

0.01
99.11764705882354 %

Como podemos observar, con un valor de $C=0.01$ nuestra precisión ha aumentado ligeramente hasta el 99.11%.

En las predicciones del modelo de Regresión Logística se obtuvo que los aciertos fueron del 97.61%. Confirmando que el modelo es bastante bueno.

Figura 43.

Predicción del modelo de Regresión Logística

```
Y_pred = modelo.predict(X_test)
score_pred = metrics.accuracy_score(Y_test, Y_pred)

print("Métrica en Test", score_pred *100, "%")
```

Figura 44.

Precisión validación del modelo Regresión Logística


Precisión del modelo 97.61904761904762 %

Se obtuvo además la matriz de confusión, la cual nos ayuda a evaluar el rendimiento de nuestro modelo de clasificación. Esta matriz compara los valores reales con los predichos por el modelo de aprendizaje. Ver Figura 45.

Este reporte nos muestra las puntuaciones de precision, recall, f1-score y support, facilitando la interpretación de los resultados del modelo.

En nuestro caso podemos ver que se utilizaron como soporte 32 señales normales, 5 señales con Taquicardia y 5 señales con Bradicardia. Además, se puede ver la precisión con la que se acertaron cada una de las clases.

F1-score es una valoración que debemos tener en cuenta, ya que es una media ponderada de la precisión y recall. En nuestro modelo los porcentajes de f1-score, son bastante buenos.

Figura 45.*Matriz de confusión del Modelo de Regresión Logística*

En la Figura 46, se puede ver el reporte de clasificación con nuestro conjunto de validación.

Figura 46.*Reporte de clasificación del modelo de Regresión Logística*

	precision	recall	f1-score	support
0	1.00	0.97	0.98	32
1	0.83	1.00	0.91	5
2	1.00	1.00	1.00	5
accuracy			0.98	42
macro avg	0.94	0.99	0.96	42
weighted avg	0.98	0.98	0.98	42

El porcentaje AUC del modelo, se muestra en la figura 47. Obteniendo un resultado bastante alto.


Figura 47.*AUC del modelo de Regresión Logística*

AUC of ROC curve: 0.9902871621621622

Finalmente generamos la curva ROC y AUC, la cual es una representación gráfica de la sensibilidad frente a la especificidad para un sistema de clasificación, es decir, consiste en una representación de la tasa de verdaderos positivos frente a la tasa de falsos positivos, para cada uno de los umbrales. El AUC, es el área bajo la curva ROC, y nos muestra el porcentaje que el modelo ha sido capaz de predecir correctamente.

Figura 48.

Gráfica curva ROC Regresión Logística



Cuanto más se aproxime a uno el valor de AUC, mejor está clasificando el modelo, mientras que si el AUC es 0.5 o menor, se entiende como un modelo ineficiente, ya que se interpreta que el modelo está clasificando de una manera completamente aleatoria.

En nuestro caso se puede observar en la curva ROC de las clases del modelo de Regresión Logística; figura 48, que el AUC resulta ser bastante óptimo, teniendo un 98% de predicciones correctas para la clase 0: Normal, un 99% de predicciones correctas para la clase 1: Taquicardia y un 100% de predicciones correctas para la clase 2: Bradicardia.

5.2 Modelo de SVM

Con los parámetros anteriormente mencionados y la técnica de K-fold aplicada, se obtuvo una precisión de entrenamiento para el modelo SVM del 97.65% como se puede ver en la Figura 49.

Figura 49.*Precisión de entrenamiento del modelo SVM*

Media de cross_validation 97.64705882352942 %

Se puede observar que el entrenamiento de este modelo fue un poco más bajo que el del modelo de Regresión Logística.

Haciendo también, la optimización del parámetro C en este modelo, se logra obtener una mejor precisión del modelo SVM, Con un C= 1e-05, se obtuvo un aumento de la precisión en entrenamiento del 98.23%. Ver figura 50.

Figura 50.*Optimización de C, en el modelo SVM*

```
from sklearn.model_selection import GridSearchCV

param_grid = {"C": [0.00001, 0.0001, 0.001,
                    0.01, 0.1, 1.0, 10.0,
                    100.0, 1000.0]}

grid = GridSearchCV(estimator = modelo,
                    param_grid = param_grid, cv = kf)

grid.fit(X_train, Y_train)
print(grid.best_estimator_.C)
print(grid.best_score_ * 100, "%")

1e-05
98.23529411764707 %
```

El parámetro C, se define como un parámetro de regularización, este parámetro puede ser ajustado en la formulación de la SVM. El ajuste de este parámetro puede hacer un balance entre la maximización del margen y la violación a la clasificación.

Pasando a las predicciones del modelo de SVM, encontramos que tuvo una precisión en la validación de 95.24%. Un resultado un poco menor al del modelo expuesto anteriormente.


Figura 51.*Precisión en validación del modelo de SVM*

```
score_pred = metrics.accuracy_score(Y_test, Y_pred)

print("Precisión validación", score_pred*100,"%")

Precisión validación 95.23809523809523 %
```

La matriz de confusión obtenida para el modelo de SVM se muestra en la figura 52.

Figura 52.*Matriz de confusión para el modelo SVM*

Observando que el modelo fue capaz de acertar 40 de las 42 predicciones posibles.

En la Figura 53, se puede ver el reporte de clasificación con nuestro conjunto de validación.

Figura 53.*Reporte de clasificación del modelo de SVM*

	precision	recall	f1-score	support
0	1.00	0.94	0.97	32
1	0.71	1.00	0.83	5
2	1.00	1.00	1.00	5
accuracy			0.95	42
macro avg	0.90	0.98	0.93	42
weighted avg	0.97	0.95	0.96	42

En este caso, con el modelo SVM se obtuvo una precisión del 100% en acertar la clase 0, un 71% en acertar la clase 1 y un 100% en acertar la clase 2.

Observando también, que los porcentajes de f1-score en este modelo son bastante eficientes.

Se obtuvo también el porcentaje de AUC del modelo SVM, este porcentaje es el resultado que nos arroja el área bajo la curva ROC, cuanto mayor es AUC, mejor será el modelo para clasificar correctamente las instancias. Ver figura 54.

Figura 54.


AUC del modelo SVM

AUC of ROC curve: 0.9266328828828829

Por último, se muestra la curva ROC Y AUC de cada una de las instancias o salidas del modelo. Ver figura 55.

Figura 55.

Curva ROC SVM



En este caso se puede observar la curva ROC de cada una de las clases; La figura 55 muestra que el AUC resulta ser también óptimo para este modelo, teniendo un 93% de predicciones correctas para la clase 0: Normal, un 85% de predicciones correctas para la clase 1: Taquicardia y un 100% de predicciones correctas para la clase 2: Bradicardia. El promedio de los tres resultados mostrados en la curva ROC se puede observar en la figura 54.

5.3 Modelo MLP

Finalmente, en este modelo de MLP se obtuvo la siguiente precisión de entrenamiento. Ver figura 56.

Figura 56.

Precisión de entrenamiento del modelo MLP

Media de cross_validation 95.58823529411764 %

Es un resultado bastante bueno, pero comparado con los otros modelos, es el menor resultado que se obtuvo.

Se hizo la optimización del parámetro Alpha (parámetro de regularización para red neuronal) de forma similar a lo que hicimos con el parámetro de regularización en regresión logística y SVM. Ver figura 57.

Figura 57.

Optimización del parámetro Alpha del modelo MLP.

```
from sklearn.model_selection import GridSearchCV
clf = MLPClassifier(solver='lbfgs', random_state=1,
                    activation='logistic',
                    hidden_layer_sizes=(12,))
param_grid = {"alpha":10.0 ** -np.arange(-4, 7)}
grid = GridSearchCV(estimator=clf, param_grid=param_grid, cv=kf)
grid.fit(X_train,Y_train)
print (grid.best_estimator_.alpha)
print (grid.best_score_*100, "%")
```

0.1

97.05882352941177 %

Se observa que con un valor de $\text{Alpha}=0.1$, el modelo mejora su precisión en el entrenamiento, aumentando a 97.05%.

Las predicciones del modelo MLP arrojaron un porcentaje de 92.86% de aciertos. Lo que se puede ver en la figura 58.

Figura 58.

Precisión de validación en el modelo MLP


```
score_pred = metrics.accuracy_score(Y_test, Y_pred)
print("Precisión validación ", score_pred *100, "%")

Precisión validación  92.85714285714286 %
```

Se obtuvo la matriz de confusión para este modelo, ver figura 59.

Figura 59.

Matriz de confusión para el modelo MLP



Observando que el modelo fue capaz de acertar 39 de las 42 predicciones posibles.

En la figura 60 se puede ver el resumen de clasificación para el modelo MLP.

Figura 60.*Resumen de clasificación del modelo MLP*

	precision	recall	f1-score	support
0	0.97	0.94	0.95	32
1	0.67	0.80	0.73	5
2	1.00	1.00	1.00	5
accuracy			0.93	42
macro avg	0.88	0.91	0.89	42
weighted avg	0.94	0.93	0.93	42


El AUC que se obtuvo con el modelo MLP, fue de 96.54%, un resultado bastante bueno, como se muestra en la figura 61.

Figura 61.*AUC del modelo MLP*

AUC of ROC curve: 0.9654138513513514

y, además, se tiene también la curva ROC y AUC de cada una de las clases a clasificar.

Ver figura 62.

Figura 62.*Curva ROC MLP*

En este modelo se muestra que el AUC resulta ser óptimo para este modelo, teniendo un 94% de predicciones correctas para la clase 0: Normal, un 95% de predicciones correctas para la clase 1: Taquicardia y un 100% de predicciones correctas para la clase 2: Bradicardia. El promedio de los tres resultados mostrados en la curva ROC se puede observar en la figura 62.

En la tabla 3 se exponen los resultados descritos anteriormente, con esta tabla determinamos que el modelo que clasifica mejor las arritmias cardiacas es la Regresión Logística, el cual fue el modelo escogido para llevar a cabo el diagnostico de cualquier señal ECG, permitiendo saber si la señal presenta taquicardia, bradicardia o si la señal es normal.

Tabla 3.

Resultados de los modelos implementados para la clasificación de las arritmias Taquicardia y Bradicardia en el entorno de Google Colab

MODELO	Accuracy	Precisión	Recall	F1-Score	ROC y AUC
RL	0.9852	0.9433	0.99	0.9633	0.9902
SVM	0.9764	0.9033	0.98	0.9333	0.9266
MLP	0.9558	0.8802	0.91	0.8933	0.9654

Estos resultados fueron obtenidos desde la ejecución en el entorno *Google Colaboratory*.

6. Comunicación, envío de datos IoT y reporte del diagnóstico.

Con anterioridad se expuso las salidas de los algoritmos implementados para el diagnóstico, 0 para pacientes normales, 1 para pacientes con taquicardia y 2 para pacientes con bradicardia. Después de este proceso, por medio de comunicación serial se envía a la ESP32.

La ESP32, se programó de tal manera que ejecute una función llamada *ProcessMsg()*, en la cual, por medio de un comparador, se ejecuta la conexión y envío del diagnóstico, mostrando la fecha y hora a un canal de ThingSpeak el cual se denominó Electrocardiografía, expuesto en la figura 64.

ThingSpeak, permite exportar estos datos de diversas maneras, desde visualizaciones y análisis en MATLAB, Tweets en Twitter hasta HTTP request. Para este proyecto, se planteó una manera de exponer la señal y su respectivo diagnóstico a través de una página web. Para esto se propuso mostrar el diagnóstico del paciente actual, por medio de una conexión HTTP, ya que esta plataforma permite observar el último dato del canal por medio de un formato de texto JSON, como se observa en la figura 65.

El lenguaje base de la página creada, es HTML y se desarrolló en Visual Studio Code, y por medio de Github se creó un repositorio para almacenar y visualizar la [página web](#). (Martinez Siado & Dovalés Galvis, s.f.)

La página posee dos botones en la parte superior derecha, el primero llamado elegir archivo y el segundo Lectura de señal los cuales se pueden ver en la figura 63. El primer botón se encarga de cargar la señal, la cual en el proceso de procesamiento de la señal se guarda un segmento de 6 segundos en un formato de valores separado por comas (.csv), el segundo botón activa la página para que esta realice su función principal.

Figura 63.


Visualización de los botones



Cuando se ejecuta el botón lectura de señal, se puede observar en la figura 66 y en la figura 67, la señal cardiaca y su diagnóstico respectivamente. La señal se programó por medio de la librería Chart.js, la cual permite exponer diversos tipos de datos en diferentes gráficas, y el diagnostico se expone con la conexión entre la página y ThingSpeak por medio de la respuesta HTTP a través de JavaScript por medio de un JSON.

Figura 64.

Canal Electrocardiografía en ThingSpeak



Como se puede observar en la figura 64, en el canal de *ThingSpeak* se muestra la fecha, hora y la clase de arritmia que tiene la persona, en este caso el último dato recibido fue 0, es decir que la persona es Normal.

Figura 65.

Solicitud HTTP en formato JSON


```

▼ {channel: {...}, feeds: Array(2)} ⓘ
  ► channel: {id: 1383805, name: "Electrocardiografia", latitude: "0.0", long...
  ▼ feeds: Array(2)
    ▼ 0:
      created_at: "2021-06-23T03:23:18Z"
      entry_id: 17
      field1: "0"
      ► __proto__: Object
    ▼ 1:
      created_at: "2021-06-23T17:57:39Z"
      entry_id: 18
      field1: "0"
      ► __proto__: Object
    length: 2
    ► __proto__: Array(0)
  ► __proto__: Object


```

Figura 66.

Segmento de la señal ECG de uno de los autores

**Figura 67.**

Diagnóstico de uno de los autores de esta investigación



7. Conclusiones

Se construyó un dispositivo electrocardiográfico portátil y de bajo costo, el cual consta con conectividad IoT permitiendo una facilidad de transmisión del diagnóstico; con un rendimiento en el entrenamiento del 98.52%, una sensibilidad del 99%, una precisión del 94.43% y un F1-score del 93.33%.

Se lograron implementar tres modelos de clasificación de arritmias cardiacas, a partir de señales ECG, con aprendizaje automático, en específico, un modelo de Regresión Logística,

un modelo SVM y un modelo MLP, que demostraron resultados comparables a otros trabajos ya presentados en la literatura. Escogiendo principalmente el modelo de Regresión Logística para abordar el diagnostico de cualquier señal tomada por el electrocardiógrafo, el cual, como se pudo observar en los resultados expuestos anteriormente fue el modelo que arrojó mejores resultados.

Mediante los reportes de clasificación resultantes de las pruebas con los diferentes modelos implementados, se puede notar que en la clase que menos precisión tuvo el modelo, fue en la clase 1, es decir, tuvo menor precisión al clasificar las taquicardias, esto se debe a que la base de datos utilizada para este proyecto tenía pocas señales ECG, que presentaran esta arritmia cardiaca.

Con el dispositivo diseñado en este proyecto, se recomienda ampliar la base de datos presentada en esta investigación, de tal manera que aumenten el número de taquicardias, Bradicardia y ritmo normal y de esta manera lograr mejores resultados de clasificación de los modelos.

Es importante aclarar que al inicio de la implementación de los modelos estábamos obteniendo sobreajuste en los datos, y ocurre normalmente cuando el tamaño de los datos de entrenamiento es pequeño. Es por esto que se optó por aplicar la técnica K-fold Validation a los modelos, la cual es una manera de predecir el ajuste de un modelo. Esta técnica nos ayudó a que los modelos implementados fueran más eficientes.

Trabajar con herramientas como *Google Colaboratory* permite ejecutar modelos de aprendizaje automático con una gran cantidad de datos y parámetros sin problemas, este entorno es muy rápido para la ejecución de los modelos, ya que se utilizan los recursos de una GPU robusta y potente como las establecidas en *Google Colab*.

De los tres modelos implementados, el que más costo computacional tuvo fue el modelo de Maquinas de Soporte Vectorial. Por ahora en este proyecto no vemos este modelo robusto para la clasificación de las arritmias de interés de esta investigación.

En definitiva, los interesados en aprender y seguir esta línea de trabajo, recomendamos realizar los cursos de Inteligencia Artificial ofrecidos por Coursera y Udacity, los cuales son proveedores de cursos en línea y nos ayudaron de manera exitosa en el desarrollo de este proyecto.

A nivel de procesamiento, se logró una automatización de un programa a través de Python para la ejecución de archivos .m o de MATLAB, para su interacción con el personal médico que use este proyecto, al igual que la página web.

La implementación de librerías como Charts.js han permitido de una manera interactiva la visualización de datos en gráficas, sin la implementación de un código tan denso en JavaScript.

8. Recomendaciones

Como trabajos futuros es necesario enfocar los esfuerzos en el desarrollo de nuevas y mejores bases de datos, para la clasificación de arritmias cardiacas, que dispongan de registros pertenecientes a un gran número de pacientes.

Queda pendiente, para la clasificación de arritmias, probar otras estructuras de aprendizaje profundo, como redes neuronales recurrentes, redes neuronales convolucionales, u otro tipo de estructura que sea capaz de manejar características temporales y morfológicas.

Se plantea para trabajo futuro el diseño propio de una PCB que cumpla con los requisitos de este proyecto, ya que para este diseño se optó por tarjetas fabricadas, disponibles en el mercado, dadas las limitaciones por la pandemia del Sars-CoV-2 y las restricciones por la emergencia sanitaria, por lo cual no se tuvo acceso a los laboratorios del campus universitario.

También se plantea como trabajo futuro, mejorar la visualización de la señal electrocardiográfica, de tal manera que se su interacción sea como la de un osciloscopio. Esto se puede lograr a través de estudios de las librerías jQuery.

Continuando con este trabajo de investigación, se recomienda realizar todo el procesamiento de la señal cardiaca y la clasificación de arritmias en el lenguaje de programación Python, ya que este software haría que el sistema planteado en este proyecto sea más asequible a cualquier persona.

Se propone a futuro que gran parte de los procesos de tratamiento y extracción de características de la señal adquirida sea procesado por la ESP, de esta manera permitirá que el acceso al artefacto llegue a ser más amplio, especialmente para aquellas personas con recursos más limitados, debido a que no necesariamente se emplearan un software como Matlab, para el desarrollo del proceso.

Referencias Bibliográficas

- American National Standard. (2012). *Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms*.
- Aragoncillo Ballesteros , P. (2010). Anatomía del Corazón. In P. Aragoncillo Ballesteros, *Libro de la Salud Cardiovascular* (pp. 35-40). Madrid.
- ATMEL. (2014, 02). *ATmega640/1280/2560/2561*. Retrieved from http://ww1.microchip.com/downloads/en/DeviceDoc/Atmel-2549-8-bit-AVR-Microcontroller-ATmega640-1280-1281-2560-2561_datasheet.pdf
- Azcona, L. (2010). El Electrocardiograma. In *Libro de la Salud Cardiovascular* (pp. 49-56). Madrid.
- Baquero Alonso, M., Rodríguez Martín, A., González Carnero, R., Gómez Santana, J., & de Haro Muñoz, J. (2010). Medicina de Familia. SEMERGEN. *ELSEVIER*.
- Berntson, G. G. (1997). Heart rate variability: origins, methods, and interpretive caveats. *Psychophysiology*.
- Blasco Vadillo, S. (2018). *La Transformada Wavelet*.
- Browser, W. (n.d.). *Biorthogonal 6.8 wavelet (bior6.8) properties, filters and functions*.
- C. Dovalés, K. M. (n.d.). *Sistema IoT para monitoreo de actividad cardiaca con variabilidad de frecuencia para el diagnóstico de enfermedades cardiovasculares*. Retrieved from <https://uis-ecg.github.io/E3T-UIS-ECG/site/>
- Calvo, D. (2017, Julio 20). *Red Neuronal Convolucional*. Retrieved from <https://www.diegocalvo.es/red-neuronal-convolucional/>
- Ciencias de la Salud*. (2009). Retrieved from <https://studylib.es/doc/5762420/el-ecg-normal-el-eje-el%C3%A9ctrico>
- Costa Gómez, T. S. (2010). *SISTEMA NERVIOSO AUTÓNOMO*. Barcelona.

- da S. Luz, E. J., Robson Schwartz, W., Cámara Chávez, G., & Menotti. (2016). ECG-based heartbeat classification for arrhythmia detection: A survey. *Science Direct*, 144-164.
- de Chazal, P., O'Dwyer, & Reilly. (2004). Automatic classification of heartbeats using ECG morphology and heartbeat interval features. *IEEE Xplore*, 1196-1206.
- De los Nietos Miguel. (2007). NOCIONES BÁSICAS DE ANATOMÍA, FISIOLOGÍA Y PATOLOGÍA CARDÍACA: BRADIARRITMIAS Y TAQUIARRITMIAS. *Enfermería en Cardiología*, 7-20.
- Devices, Analog. (n.d.). AD8232. Retrieved from <https://www.analog.com/media/en/technical-documentation/data-sheets/ad8232.pdf>
- Educba. (2019, Diciembre 30). *Laptrinhx*. Retrieved from Perceptron Learning Algorithm: <https://laptrinhx.com/perceptron-learning-algorithm-942489587/>
- Electronics, D. (n.d.). *ESP32s Board con Wifi bluetooth (ESP-WROOM-32)* - *DynamoElectronics*.
- Electrophysiology, T. F. (1996). *Heart rate variability: standards of measurement, physiological interpretation, and clinical use*.
- ESPRESSIF. (2021). *ESP32 WROOM32 DATASHEET*. Retrieved from https://www.espressif.com/sites/default/files/documentation/esp32-wroom-32_datasheet_en.pdf
- Fajurí, A. (2009). *Manual de Arritmias*.
- Ferreira Rodriguez, P., & Monteiro Filho, J. M. (2019). Chapter 7 - The Issue of Automatic Classification of Heartbeats. *Science Direct*, 169-193.
- Fred Shaffer, J. P. (2017). *An Overview of Heart Rate Variability Metrics and Norms*. Retrieved from [https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5624990/#:~:text=Heart%20rate%20is%20the%20number,nervous%20system%20\(ANS\)%20processes](https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5624990/#:~:text=Heart%20rate%20is%20the%20number,nervous%20system%20(ANS)%20processes).

- Garcia Rubira, J. C. (2010). Fisiología Cardíaca. In *Libro de la Salud Cardiovascular* (pp. 41-47). Madrid.
- Gove, R., & Faytong, J. (2012). Machine Learning and Event-Based Software Testing: Classifiers for Identifying Infeasible GUI Event Sequences. *Science Direct*.
- Greenwald, Scott David. (1999, Agosto 3). *Physionet*. Retrieved from MIT-BIH Malignant Ventricular Ectopy Database: <https://physionet.org/content/vfdb/1.0.0/>
- Hakim Vista, J. (2017, Agosto 08). *itmo sinusal, arritmias del nodo sinusal*. Retrieved from <https://www.cardioscience.com.mx/nota.php?id=263>
- Larrañaga, P., Inza, I., & Moujahid, A. (2018). *Redes Neuronales*.
- Li, C. Z. (1995). Detection of ECG characteristic points using wavelet transforms. *IEEE Transactions on biomedical Engineering*,.
- Luiz Carlos Marques Vanderlei, C. M. (2010). ndices geométricos de variabilidad de la frecuencia cardíaca en niños obesos y eutróficos. *Scielo Brasil*.
- Mallat, S. (1991). Zero-crossings of a wavelet transform. *IEEE Xplore*, 1019-1033.
- Mallat, S., & Hwang, W. (1992). Singularity detection and processing with wavelets. *IEEE Xplore*, 617-643.
- Mao, W., & Wang, F. (2012). Cultural Modeling for Behavior Analysis and Prediction. *Science Direct*.
- Martínez, J. P. (2004). A wavelet-based ECG delineator: evaluation on standard databases. *IEEE Transactions on biomedical engineering*.
- Meneses Arévalo , A., & Toloza Cano, D. C. (2008, Enero). *ResearchGate*. Retrieved from Unidad Modular de Electrocardiografía de 12 derivaciones: https://www.researchgate.net/publication/301892295_Unidad_Modular_de_Electrocardiografia_de_12_derivaciones

- Moody, G. (1999, Agosto 3). *Physionet*. Retrieved from MIT-BIH Normal Sinus Rhythm Database: <https://physionet.org/content/nsrdb/1.0.0/>
- Muñoz, A. (2009). *Electrocardiografía Básica*. Colombia: Universidad del Rosario.
- Negrete Salcedo, A., & Hoyos Usta, A. (2015). *Bradiarritmias*.
- Niño, C. A. (2011). *Sistema de procesamiento y análisis de la señal cardiaca como indicador del balance del sistema nervioso autónomo y su correlación con datos tomográficos en pacientes con accidentes cerebrovascular*. Bucaramanga.
- Nolle, Badura, catlett, Bowser, & Sketch. (1986). *Physionet*. Retrieved from Creighton University Ventricular Tachyarrhythmia Database: <https://archive.physionet.org/physiobank/database/cudb/>
- Pérez, E. M. (2007). *Microcontroladores PIC: sistema integrado para el autoaprendizaje*. Marcombo.
- Raspberry Pi. (n.d.). *Buy a Raspberry Pi 3 Model B - Raspberry Pi*. Retrieved from <https://www.raspberrypi.org/products/raspberry-pi-3-model-b/>
- Riberos Sanabria, F. (2012). *Analisis con Wavelets de alteraciones electrocardiográficas en pacientes chagásticos crónicos*. Medellin: Universidad EAFIT.
- Robledo Carmona, J. M., Jiménez Navarro, M., & Robledo Carmona, L. (2007). *Electrocardiograma*. Malaga.
- Rodas, G., Pedret Carballido, C., Ramos , J., & Capdevila, L. (2008). VARIABILIDAD DE LA FRECUENCIA CARDIACA: CONCEPTO, MEDIDAS Y RELACIÓN CON ASPECTOS CLINICOS (I). In *Archivos de medicina del deporte* (p. 6). Barcelona.
- Rodriguez Mañero , M. (2018). ARRITMIAS. *Fundación Española del Corazón*.
- ROMERO, J. L. (2015). *ANÁLISIS DE SEÑALES ELECTROCARDIOGRÁFICAS USANDO TÉCNICAS DE PROCESAMIENTO DIGITAL*.

- Saenz Bajo, N., Barrios Rueda, E., Conde Gómez, M., Domínguez Macías, I., López Carabaño, A., & Méndez Díez, C. (2002). Uso de redes neuronales en medicina: a propósito de la patología dispéptica. *ELSEVIER*, 3.
- Sanchez Fuentes, M. J., & Montero Parra, R. A. (2007). *Construcción de una base de datos de señales electrocardiográficas y datos clínicos de pacientes con diagnóstico de diabetes mellitus, enfermedad cerebro-vascular, infarto agudo del miocardio y/o arritmia cardíaca; y medición de la VFC en dichos pacientes*. Bucaramanga: Universidad Industrial de Santander.
- Sgarlatta, A. (2016). *Sensor inalámbrico de ECG conectado vía Bluetooth a aplicación de análisis automático en el teléfono móvil*. Córdoba: Universidad Nacional de Córdoba.
- SparkFun. (n.d.). *AD8232-Heart-Rate-Monitor-V10*. Retrieved from https://cdn.sparkfun.com/datasheets/Sensors/Biometric/AD8232_Heart_Rate_Monitor_v10.pdf
- Texas Heart Institute. (2012). *Anatomía del Corazón*. Retrieved from <https://www.texasheart.org/heart-health/heart-information-center/topics/anatomia-del-corazon/>
- Umetani K, S. D. (2011). Twenty-four hour time domain heart rate variability and heart rate: relations to age and gender over nine decades. *Ann Noninvasive Electrocardiology*.
- Urso, A., & Rizzo, R. (2019). Data Mining: Prediction Methods. *Science Direct*.
- Vedado, F. (2010). *Las derivaciones del electrocardiograma*.
- Vogler, J., Breithardt, G., & Eckardt, L. (2012). Bradiarritmias y bloqueos de la conducción. *Revista Española de Cardiología*, 656- 667.
- World Health Organization . (2011). *New WHO report: deaths from noncommunicable diseases on the rise, with developing world hit hardest*.
- World Health Organization. (2020). *The top10 causes of death*.

Zavala Villeda, J. A. (2017, junio 1). *Descripción del electrocardiograma normal*. Retrieved from <https://www.medigraphic.com/pdfs/rma/cma-2017/cmas171bj.pdf>


Apéndices

Apéndice A. Conceptos básicos utilizados para la elaboración de este proyecto de investigación.

Anatomía del corazón: El corazón es un órgano muscular hueco localizado en la cavidad torácica, justo por encima del diafragma. Su tamaño varía con la edad, el sexo y la superficie corporal del individuo, aunque en una persona adulta normalmente oscila entre los 220-300g (De los Nietos Miguel, 2007). Se encuentra envuelto por una bolsa serosa; el pericardio, que constituye la capa externa del corazón (De los Nietos Miguel, 2007). La parte interna del corazón está constituida por cuatro cavidades: Dos en el lado derecho y dos en el izquierdo, Las cavidades situadas en la parte superior se denominan aurículas, y las dispuestas en la parte inferior, ventrículos (Aragoncillo Ballesteros , 2010). En condiciones normales, las cavidades derechas no se comunican con las izquierdas, pues se hallan divididas por un tabique muscular, denominado tabique interauricular, que separa ambas aurículas; el tabique que distancia ambos ventrículos se llama interventricular (Aragoncillo Ballesteros , 2010). Son fundamentalmente los ventrículos los que se encargan del trabajo de impulsar la sangre. Las aurículas, en cambio, contribuyen al relleno óptimo de los ventrículos en cada latido.

Figura 68.

Anatomía del Corazón



Nota: Tomada de (Texas Heart Institute, 2012)

Regulación Cardíaca: El corazón cuenta con un sistema que genera contracciones rítmicas adecuadas a cada situación del organismo. Éste no se controla de forma voluntaria. Su regulación depende del llamado sistema nervioso autónomo, que tiene dos componentes: el sistema simpático y el sistema parasimpático (García Rubira, 2010). El componente simpático produce un aumento en la frecuencia cardíaca, y un incremento en la fuerza de contracción cardíaca. El componente parasimpático se ocupa de lo contrario: disminuye la frecuencia cardíaca y la fuerza de contracción. En una situación de normalidad, ambos componentes se mantienen en equilibrio, pero en determinadas ocasiones, uno predomina sobre el otro. Por ejemplo, durante el ejercicio existe una activación simpática que origina, entre otras cosas, un aumento de la fuerza de contracción y de la frecuencia cardíaca. En el otro extremo, un estímulo potente del sistema parasimpático puede producir una bajada importante en la frecuencia cardíaca.

Arritmias con ritmo Sinusal

Cuando la frecuencia cardíaca se ve alterada, pero las características del ritmo cardíaco son las del ritmo sinusal normal, se habla de arritmias con ritmo sinusal.

Arritmia sinusal: Es la variación de la frecuencia cardíaca del nodo sinusal con la respiración. La frecuencia cardíaca se acelera durante la inspiración y se desacelera durante la espiración. Se trata de un fenómeno normal que se da en personas saludables, especialmente jóvenes y niños; Ver figura 69.

Figura 69.

Arritmia sinusal respiratoria




Nota: Tomada de (Baquero Alonso, Rodríguez Martín, González Carnero, Gómez Santana, & de Haro Muñoz, 2010).

Taquicardia sinusal: Al contrario de la bradicardia, la taquicardia se da cuando la frecuencia cardíaca supera los 100 lpm. Se puede observar en situaciones fisiológicas: en la infancia, durante o después de un ejercicio físico intenso, o debido a determinados estados emocionales; Ver figura 70.

Figura 70.

Taquicardia Sinusal



Nota: Tomada de (Sgarlatta, 2016).

Arritmias supraventriculares: Son aquellas que requieren de estructuras ubicadas por encima de la bifurcación del haz de His. Las arritmias supraventriculares activas pueden corresponder a de polarizaciones aisladas precoces (extrasístoles) o taquiarritmias supraventriculares, como las taquicardias paroxísticas supraventriculares, el aleteo y fibrilación auriculares.

Extrasístoles supraventriculares: Pueden originarse en la aurícula, en la unión A-V o en el nódulo sinusal mismo. Se reconocen en el electrocardiograma por la aparición de un complejo QRS angosto prematuro, precedido o no de onda P. Las extrasístoles supraventriculares constituyen un hallazgo frecuente en personas normales, especialmente de edad avanzada (Fajurí, 2009); Ver figura 71.

Figura 71.

Extrasístoles supraventriculares



Nota: Tomada de (Sgarlatta, 2016).

Taquicardia paroxística supraventricular: Ocurre cuando se producen descargas regulares en las aurículas o en el nodo AV, con una frecuencia de entre 100 y 250 lpm. Se denomina paroxística, porque el aumento en la frecuencia cardíaca comienza de manera repentina. El paroxismo puede durar unos segundos, unos minutos, algunas horas o más, y cesa tan repentinamente como comenzó (Sgarlatta, 2016).

Figura 72.

Taquicardia paroxística supraventricular




Nota: Tomada de (Sgarlatta, 2016).

Aleteo auricular: El aleteo auricular o flutter auricular (AA) es una taquiarritmia supraventricular muy frecuente, en la cual existe un camino de conducción en forma de círculo alrededor de la aurícula derecha por la cual el impulso eléctrico viaja siempre en la misma dirección. Esto produce una contracción rápida de las aurículas, a una frecuencia de entre 200 y 350 lpm.

En el ECG, esto se traduce a un patrón característico de “dientes de sierra” dado por las sucesivas ondas P fusionadas, intercalado con complejos QRS normales; Ver figura 73.

Figura 73.

Aleteo auricular




Nota: Tomada de (Baquero Alonso, Rodríguez Martín, González Carnero, Gómez Santana, & de Haro Muñoz, 2010).

Fibrilación Auricular: Se caracteriza en el electrocardiograma por la una activación no coordinada a una frecuencia entre 400 y 700 latidos por minuto, lo que conlleva al deterioro de su función mecánica.

Figura 74.

Fibrilación Auricular




Nota: Tomada de (Baquero Alonso, Rodríguez Martín, González Carnero, Gómez Santana, & de Haro Muñoz, 2010).

Arritmias ventriculares: Son aquellas en las que los latidos tienen su origen en los ventrículos. Dentro de este grupo se describirán las extrasístoles ventriculares, la taquicardia y la fibrilación ventriculares (Sgarlatta, 2016).

Extrasístoles ventriculares: Al igual que las extrasístoles supraventriculares, son latidos que aparecen antes de tiempo, pero en este caso generados por un foco ectópico en alguno de los ventrículos. Los complejos QRS correspondientes a estos latidos se caracterizan por ser anchos, con una duración mayor a 0.12 s, debido a que el impulso se propaga en los ventrículos lentamente de miocito a miocito en vez de hacerlo a través de las fibras de Purkinje de conducción rápida (Fajurí, 2009).

Figura 75.

Extrasístole ventricular




Nota: Tomada de (Sgarlatta, 2016).

Fibrilación ventricular: Los trastornos de la actividad eléctrica del corazón, provocan que las cámaras inferiores del corazón; los ventrículos, se agiten o fibrilen, en lugar de contraerse o latir con normalidad.

En el ECG, la fibrilación ventricular se asocia con una apariencia de “bolsa de gusanos”. No se distingue ningún patrón repetitivo, sólo se observan ondas irregulares que en un principio tienen una amplitud de unos 0.5 mV, pero rápidamente van decayendo y entre 20 y 30 segundos más tarde son de entre 0.2 y 0.3 mV.

Figura 76.

Fibrilación ventricular




Nota: Nótese que no es posible determinar claramente la morfología de los complejos QRS-T. Las ondas fibrilatorias varían en contorno y amplitud entre ellas. Tomada de (Negrete Salcedo & Hoyos Usta, 2015).

Bloqueos: Cuando la conducción normal del impulso eléctrico en el corazón se ve interrumpida o demorada en alguno de los puntos del camino, se habla de un bloqueo. Dependiendo del punto en el que se dé la demora o interrupción en la conducción, existen tres tipos diferentes de bloqueos: El sinoauricular, el auriculoventricular, y los bloqueos de rama. Algunos de los distintos bloqueos pueden observarse en la figura 77.

Figura 77.

Diferentes tipos de Bloqueos cardiacos



Nota: Tomada de (Vogler, Breithardt, & Eckardt, 2012).

Bloqueo sinoauricular: En este tipo de bloqueo, el nodo SA descarga de manera normal pero el impulso eléctrico no logra ser propagado hacia las aurículas. En consecuencia, hay ausencia de ondas P. Sin embargo, al no recibir las descargas provenientes del nodo SA, el nodo AV comienza a latir a su propio ritmo, generándose así un ritmo ventricular más lento, pero de morfología normal (Sgarlatta, 2016).

Bloqueo auriculoventricular: El problema está en la conducción del impulso entre las aurículas y los ventrículos, debido a alguna falla en el nodo AV o en el haz de His. Este bloqueo puede darse en tres grados.

El bloqueo AV de primer grado se produce un retraso en paso del estímulo por el nodo AV o el sistema His-Purkinje, retrasando la aparición del complejo QRS.

El bloqueo AV de segundo grado, se produce una interrupción discontinua del paso del estímulo de las aurículas a los ventrículos, observándose en el electrocardiograma Ondas P no seguidas de QRS.


Finalmente, el bloqueo AV de tercer grado o completo se da cuando ninguno de los latidos es capaz de ser conducido desde las aurículas hacia los ventrículos. El nodo AV

comienza a descargar a su propia frecuencia, y se produce una disociación entre la frecuencia auricular y la ventricular. No hay ninguna relación entre las ondas P y los complejos QRS.

Apéndice 2. Respuesta en frecuencia del monitor cardiaco.

Figura 78.

Respuesta en frecuencia del monitor cardiaco AD8232



Nota. Adaptado de la hoja de datos del AD8232 (Devices, Analog)