



**Determinación de valvulopatías cardíacas a través del análisis de sonidos del
corazón mediante algoritmos de machine learning**

Montaluisa Molina, Luis Eduardo

Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica y Telecomunicaciones

Trabajo de titulación, previo a la obtención del título de Ingeniero en Electrónica y
Telecomunicaciones

Dr. Pineda López, Flavio Minos Ph.D.

18 de marzo del 2021

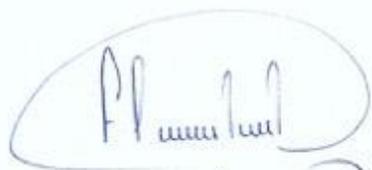


Document Information

Analyzed document	Proyecto Pregrado_Luis Montaluisa_URKUND.pdf (D99854822)
Submitted	3/26/2021 9:07:00 PM
Submitted by	Pineda López Flavio Minos
Submitter email	fmpineda@espe.edu.ec
Similarity	1%
Analysis address	fmpineda.espe@analysis.orkund.com

Sources included in the report

W	URL: https://docplayer.es/76260820-Ecg-analogico-controlado-por-arduino-para-monitoriza... Fetched: 7/8/2020 12:02:32 AM	 1
SA	Universidad de las Fuerzas Armadas ESPE / Tesis BLeppo.pdf Document Tesis BLeppo.pdf (D60992835) Submitted by: mjflores@espe.edu.ec Receiver: mjflores.espe@analysis.orkund.com	 1
W	URL: https://docplayer.es/153936880-Clasificacion-de-los-sonidos-cardiacos-usando-ondic... Fetched: 2/6/2020 2:01:59 PM	 1


Ing. Flavio Pineda PHD
Docente DEET
C.I: 1102866660



**DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA Y
TELECOMUNICACIONES**

CERTIFICACIÓN

Certifico que el trabajo de titulación, “**Determinación de valvulopatías cardíacas a través del análisis de sonidos del corazón mediante algoritmos de machine learning**” fue realizado por el señor **Montaluisa Molina, Luis Eduardo** el cual ha sido revisado y analizado en su totalidad por la herramienta de verificación de similitud de contenido; por lo tanto cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, razón por la cual me permito acreditar y autorizar para que lo sustente públicamente.

Sangolquí, 18 de marzo del 2021

Ing. Flavio Minos Pineda López, Ph.D.

C. C. 1102866660



**DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA Y
TELECOMUNICACIONES**

RESPONSABILIDAD DE AUTORÍA

Yo, **Montaluisa Molina, Luis Eduardo**, con cédula de ciudadanía n°1717984320, declaro que el contenido, ideas y criterios del trabajo de titulación: **“Determinación de valvulopatías cardíacas a través del análisis de sonidos del corazón mediante algoritmos de machine learning”** es de mi autoría y responsabilidad, cumpliendo con los requisitos legales, teóricos, científicos, técnicos, y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Sangolquí, 18 de marzo del 2021

Montaluisa Molina, Luis Eduardo

C.C.: 1717984320



**DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES**
**CARRERA DE INGENIERÍA EN ELECTRÓNICA Y
TELECOMUNICACIONES**

AUTORIZACIÓN DE PUBLICACIÓN

Yo, **Montaluisa Molina, Luis Eduardo**, con cédula de ciudadanía n°1717984320, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **“Determinación de valvulopatías cardíacas a través del análisis de sonidos del corazón mediante algoritmos de machine learning”**, en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Sangolquí, 18 de marzo del 2021

Montaluisa Molina, Luis Eduardo

C.C.: 1717984320

Dedicatoria

El presente trabajo se lo dedico a Dios, por permitirme ser y estar en esta vida y por regalarme cada una de las oportunidades en el camino, a mi madre por su amor infinito, su entrega y su abnegación en cada día.

A mi padre por su sacrificio y amor al procurar que cumpla con mis metas profesionales, a mis hermanos por su apoyo incondicional y por su confianza en mi, por ser mi soporte y mi inspiración en cada momento.

A toda mi familia por desear lo mejor para mí, por la preocupación y los consejos para continuar y no desmayar en la consecución del objetivo brindándome siempre su cariño.

Luis Eduardo Montaluisa

Agradecimiento

A mis maestros, aquellos que me han enseñado a largo de este etapa no solo la ciencia y la tecnología, sino además la manera de enfrentar cada uno de los obstáculos que se presenten.

A mi director de tesis Dr. Flavio Minos Pineda L., Ph.D., por su apoyo, por los conocimientos impartidos y por la confianza al poner en mis manos el presente proyecto.

A mis compañeros en cada una de las etapas de la vida académica, con quienes he compartidos grandes momentos, experiencias, retos y dificultades, las mismas que nos han permitido crecer como personas y profesionales.

A las personas que considero amigas, que con cada palabra de aliento me impulsan a continuar y no decaer, que se preocupan en las dificultades y se alegran en mis aciertos, gracias.

Luis Eduardo Montaluisa

Contenido

<i>Análisis de URKUND</i>	2
<i>Certificación</i>	3
<i>Responsabilidad de Autoría</i>	4
<i>Autorización de publicación</i>	5
<i>Dedicatoria</i>	6
<i>Agradecimiento</i>	7
<i>Contenido</i>	8
<i>Índice de tablas</i>	12
<i>Índice de figuras</i>	13
<i>Resumen</i>	16
<i>Abstract</i>	17
<i>Capítulo I</i>	18
<i>Introducción</i>	18
<i>Antecedentes</i>	18
<i>Motivación</i>	19
<i>Importancia</i>	20
<i>Alcance del Proyecto</i>	21

Objetivos	23
Objetivo General	23
Objetivos Específicos	23
Capítulo II.....	24
Estado del Arte	24
Métodos de medición y análisis de sonidos cardíacos.....	24
Modelos de Machine Learning aplicados a señales fisiológicas	27
Fundamentos Teóricos	33
Señales FCG/PCG.....	33
Anatomía de las válvulas y cavidades cardíacas.....	35
Funcionamiento de las válvulas cardíacas	37
Ciclo cardíaco	37
Sonidos Cardíacos	39
Auscultación de sonidos cardíacos	43
Soplos cardíacos.....	44
Valvulopatías	45
Redes Neuronales Convolucionales.....	46
Capítulo III.....	50
Desarrollo del algoritmo de detección y clasificación de arritmias	50
Introducción.....	50

	10
Diagrama de bloques del sistema.....	51
Etapa de pre procesamiento	52
Segmentación de señales pre procesadas.....	56
Extracción de características.....	60
Clasificador basado en CNN	63
Entrenamiento del clasificador	64
Visualización de señal procesada	65
Diseño de la interfaz gráfica	66
Diagrama de flujo de la interfaz	67
Funcionamiento de la interfaz.....	68
Capítulo IV.....	73
Pruebas y análisis de resultados	73
Primer escenario de pruebas	73
Segundo escenario de pruebas	79
Matriz de confusión.....	81
Resultados de las pruebas con el segundo escenario	82
Capítulo V.....	84
Conclusiones y recomendaciones	84
Conclusiones.....	84
Recomendaciones	85

Trabajos futuros.....	86
<i>Bibliografía</i>	<i>87</i>
<i>Anexos</i>	<i>92</i>

Índice de tablas

Tabla 1 Clasificación de Valvulopatías.....	22
Tabla 2 Sensibilidad y Valores Predictivos Positivos con DHMM y HMM.....	25
Tabla 3 Comparación de los Resultados de Trabajos Similares.....	32
Tabla 4 Principales Sonidos Fisiológicos y Patológicos	41
Tabla 5 Resultados de las Pruebas del Escenario 1	78
Tabla 6 Matriz de Confusión Simple	82

Índice de figuras

Figura 1 Representación de una Señal ECG y una Señal PCG	34
Figura 2 Cavidades Cardíacas	35
Figura 3 Cavidades y Válvulas del Corazón	36
Figura 4 Funcionamiento de las Válvulas Cardíacas.....	38
Figura 5 Fases del Ciclo Cardíaco	39
Figura 6 Sonidos Fundamentales S1 y S2.....	40
Figura 7 Sonidos S3 y S4.....	42
Figura 8 Áreas de Auscultación.....	43
Figura 9 Soplos en las Fases del Ciclo Cardíaco	44
Figura 10 Principales Valvulopatías: Insuficiencia y Estenosis	46
Figura 11 Aplicación de Filtros a una Capa de Entrada	47
Figura 12 Ejemplo de capas de convolución	49
Figura 13 Diagrama de Bloques para la Detección de Valvulopatías	51
Figura 14 Diagrama de Pre Procesamiento de Señales PCG	53
Figura 15 Señal PCG Normalizada	54
Figura 16 Código de Matlab de Pre Procesamiento de la Señal.....	55
Figura 17 Gráfica de la Señal Original vs la Señal Filtrada.....	56
Figura 18 Diagrama de Bloques del Algoritmo de Segmentación.....	57
Figura 19 Segmentos S1, S2, Sístole y Diástole Identificados	58

Figura 20 Código de Matlab para Implementar el Algoritmo de Segmentación.....	59
Figura 21 Gráfica de la Identificación de Segmentos en la Señal PCG.....	60
Figura 22 Representación de los Registros PCG en Bandas de Frecuencia	61
Figura 23 Código de Matlab para la Extracción de Características	62
Figura 24 Arquitectura de CNN para Clasificación de Ruidos Cardíacos	64
Figura 25 Código de Matlab del Clasificador de Ruidos Cardíacos	65
Figura 26 Diseño de la interfaz.....	66
Figura 27 Diagrama de Flujo de la Interfaz.....	67
Figura 28 Explorador de Archivos	68
Figura 29 Visualización de Señal Pre Procesada.....	69
Figura 30 Visualización de los segmentos de la señal y el diagnóstico.....	70
Figura 31 Almacenamiento de la señal filtrada en directorio local	71
Figura 32 Almacenamiento de la señal filtrada en directorio local	71
Figura 33 Visualización de la señal filtrada almacenada desde la interfaz.....	72
Figura 34 Primer Escenario de Pruebas	73
Figura 35 Señal filtrada del registro b0040.wav.....	74
Figura 36 Señal segmentada del registro b0040.wav.....	75
Figura 37 Señal filtrada del registro c0031.wav	75
Figura 38 Señal segmentada del registro c0031.wav.....	76
Figura 39 Señal filtrada del registro b0061.wav.....	77

Figura 40 Señal segmentada del registro b0061.wav.....	77
Figura 41 Segundo Escenario de pruebas.....	79
Figura 42 Código de Matlab del Script.....	80
Figura 42 Matriz de Confusión y Métricas de Desempeño	83

Resumen

Las patologías asociadas al mal funcionamiento de las válvulas cardíacas constituyen un gran porcentaje de las enfermedades del corazón en general; su diagnóstico representa un reto para los médicos de atención primaria, incluso para médicos especialistas ya que se requiere de un oído entrenado y expertis en el campo para interpretar los sonidos del corazón, ya sea a través de la escucha o a través de la visualización de las señales cardíacas. En este trabajo se desarrolla un algoritmo de clasificación de sonidos cardíacos utilizando redes neuronales convolucionales (CNN) para la determinación de valvulopatías. Se realizó una etapa de pre procesamiento de la señal de fono cardiograma (PCG), que inicia con un re muestreo de la señal a 1000Hz, a continuación, se normalizó la señal y se realizó un proceso de filtrado entre 25 – 400 Hz. Posteriormente se segmentaron los sonidos cardíacos utilizando el modelo de semi Markov oculto (HSMM) que permite determinar los sonidos S1, S2, y las etapas sístole y diástole del ciclo cardíaco. Entonces se extrajeron las características de la señal descomponiendo la misma en cuatro bandas de frecuencia que se utilizaron como entrada de la CNN. Para la evaluación del clasificador se consideraron 301 registros del subconjunto de validación de la base de datos de Physionet, los resultados de las estadísticas obtenidas fueron 91.4% de especificidad y 75.3% de sensibilidad.

Palabras clave:

- **VALVULOPATÍAS**
- **APRENDIZAJE AUTOMÁTICO**
- **REDES NEURONALES CONVOLUCIONALES**
- **SEGMENTACIÓN**

Abstract

Pathologies associated with heart valve malfunction constitute a large percentage of heart disease in general; Its diagnosis represents a challenge for primary care physicians, even specialist physicians, since it requires a trained ear and expertise in the field to interpret heart sounds, either through listening or through visualization of the sounds. heart signals. In this work, a cardiac sound classification algorithm is developed using convolutional neural networks (CNN) for the determination of valvular heart disease. A preprocessing stage of the phonocardiogram signal (PCG) was carried out, which begins with a resampling of the signal at 1000Hz, then the signal was normalized, and a filtering process was carried out between 25-400 Hz. Subsequently, the sounds were segmented using the hidden semi-Markov model (HSMM) that allows determining the S1, S2 sounds, and the systole and diastole stages of the cardiac cycle. The characteristics of the signal were then extracted by decomposing it into four frequency bands that were used as CNN input. For the evaluation of the classifier, 301 records of the validation subset of the Physionet database were considered, the results of the statistics obtained were 91.4% specificity and 75.3% sensitivity.

Key words:

- **VALVE DISEASES**
- **MACHINE LEARNING**
- **CONVOLUTIONAL NEURAL NETWORKS**
- **SEGMENTATION**

Capítulo I

Introducción

Antecedentes

Las enfermedades cardiovasculares (ECV), han sido en las últimas décadas el conjunto de causas más comunes de mortalidad en el mundo, especialmente en los países en vías de desarrollo o de ingresos medios – bajos cuyo índice aumenta con cada año llegando a más del 75% de la estimación mundial, en contraste con los países de ingresos altos que presentan disminución de mortalidad en su población asociados a las ECV. (WHO, 2017)

A nivel mundial conforme datos de la Organización Mundial de la Salud se estima que en el año 2015 murieron 17,7 millones de personas a causa de enfermedades cardiovasculares lo cual representa un 31% de todas las muertes registradas en el mundo, de estas muertes, 7,4 millones se debieron a cardiopatías coronarias, de los 17 millones de muertes de personas menores de 70 años atribuibles a enfermedades no transmisibles, un 82% corresponden a los países de ingresos bajos y medios y un 37% se deben a las ECV. (WHO, 2017)

Además del impacto social que conlleva la mortalidad por ECV, también supone un impacto económico, obedeciendo a la muerte prematura de la población económicamente activa, ya que pueden reducir el PIB hasta en un 6,77% en los países en vías de desarrollo.

Esta población en su mayoría no cuenta con programas de atención primaria integrados y eficientes que permitan la detección temprana y el tratamiento adecuado y

oportuno, como resultado muchos habitantes de dichos países mueren más jóvenes, y en la edad más productiva.

En Ecuador según datos recogidos por el Instituto Nacional de Estadísticas y Censos del Ecuador (INEC), en el año 2014 se reportaron un total de 4 430 muertes por enfermedades isquémicas del corazón, mientras que, por insuficiencia cardíaca, los fallecimientos llegaron a 1 316, las arritmias cardíacas sumaron un total de 168 muertes, mientras que los fallecidos por paros cardíacos en ese mismo año fueron 106. (INEC, 2014)

En marzo de 2016, la Organización Panamericana de la Salud (OPS), llevó a cabo un estudio en Ecuador sobre las poblaciones en riesgo de padecer enfermedades cardiovasculares, determinando que un total del 30% de la población adulta entre 40 y 69 años corre riesgo de padecer alguna enfermedad asociada con el mal funcionamiento del sistema cardíaco. (PAHO, 2016)

Motivación

En general para determinar las afecciones cardíacas de manera oportuna y efectiva existen 4 procedimientos clínicos complementarios con diagnósticos propios que permiten establecer con claridad una cardiopatía específica, que son:

- Fonocardiograma: registra los sonidos cardiacos relacionados al flujo de sangre a través de sus válvulas.
- Electrocardiograma: mide la actividad eléctrica del corazón, y las irregularidades en los latidos de este.

- Radiografía: permite visualizar el tamaño y la forma del corazón, así como elementos no propios del sistema cardiovascular.
- Ecocardiografía: para examinar el funcionamiento de las válvulas, los movimientos del corazón, su tamaño y forma en tiempo real.

El fonocardiograma es el procedimiento de atención primaria básico e imprescindible de primera instancia que puede realizar un médico para valorar la condición cardíaca del paciente, previo al direccionamiento con un especialista si así se requiere.

Considerando que el diagnóstico oportuno de las afecciones cardíacas puede reducir de manera considerable la mortalidad de la población y en busca de mejorar los métodos y procedimientos, y observando como las señales fono cardiográficas son una forma de hacer un estudio de las enfermedades cardiovasculares, el presente trabajo se plantea el análisis de los sonidos del corazón desde su parte matemática y determinística.

Importancia

La evolución en la tecnología médica ha permitido que muchos de los instrumentos análogos usados por los médicos para la valoración de la salud de las personas evolucionen a instrumentos digitales de mayor precisión apoyados en transductores de alta fiabilidad, que permiten el análisis profundo de las señales adquiridas.

Aprovechando las ventajas de las señales digitales, como la capacidad de filtración, segmentación, aumento de niveles de la señal, escucha y visualización de las señales grabadas, entre otros, sin embargo, la detección de cardiopatías o

enfermedades cardiovasculares es un reto importante incluso para un médico especializado en cardiología, a causa de la gran cantidad de información tomada de los pacientes.

En el caso de las señales obtenidas en un fonocardiograma, el análisis de los sonidos y ruidos del corazón se basan en la experiencia y pericia del médico, por lo tanto, puede inducirse al error humano, es entonces cuando el procesamiento de señales toma importancia en la detección de anomalías cardiovasculares.

Así los modelos matemáticos cualitativos y cuantitativos utilizados en los algoritmos de aprendizaje automático para la construcción de modelos estadísticos basados en datos representativos permiten establecer de manera más fiable las características referentes de los sonidos cardíacos, así como la determinación de anomalías específicas.

Alcance del Proyecto

El presente proyecto tiene como propósito, determinar la presencia de patologías en las válvulas del corazón, la cuales pueden encontrarse tanto en la etapa de contracción, como en la etapa de relajación en el ciclo cardíaco.

El estudio extrae los sonidos característicos S1 y S2 que conforman la base o estado normal, así como sus etapas de sístole y diástole, de las cual se desprende el análisis y la identificación de valvulopatías, que dada la complejidad de la información pueden interpretarse de manera errónea como señales fisiológicas.

El algoritmo busca identificar las siguientes valvulopatías de acuerdo con el área de auscultación y etapa donde se registra, conforme el siguiente cuadro:

Las señales son tomadas de la base de datos de Physionet, que cuentan con registros de cada uno de los focos de auscultación: F. Pulmonar, F. Aórtico, F. Tricúspide y F. Mitral, tanto de pacientes sanos como de pacientes con afecciones cardíacas, entre los que se incluyen las valvulopatías.

Tabla 1

Clasificación de Valvulopatías

Subconjunto	Patología	Válvula
a	Valvulopatía	Aórtica
b	Valvulopatía	Pulmonar
c	Valvulopatía	Mitral
d	Valvulopatía	Tricuspídea

Los registros requieren de un pre procesamiento de las señales, que permitan discriminar los sonidos del corazón de los ruidos generados por la manipulación de los instrumentos de adquisición, así como de los movimientos de los pacientes al momento de la auscultación, y del entorno.

Posteriormente se realizará la segmentación de la señal que permita establecer las fases del ciclo cardíaco y sus componentes para luego extraer las características de un porcentaje de sonidos para su clasificación. La determinación de las diferentes valvulopatías se realizará mediante redes neuronales artificiales (ANN), la red neuronal estará compuesta por las siguientes capas: capa de entrada, capa de salida y capa

oculta. El proyecto incluirá una interfaz gráfica para el análisis de los sonidos cardíacos, que incluyen las siguientes características:

- Permitirá elegir el registro del sonido cardíaco con el que se va a trabajar.
- Se mostrará la señal antes y después del pre procesamiento.
- Se visualizará los sonidos característicos S1, S2, y las etapas diastólica y sistólica.
- Desplegará el diagnóstico del registro del paciente.

Objetivos

Objetivo General

Desarrollar un algoritmo para la detección de lesiones valvulares del corazón en base a los registros fono cardiográficos de Physionet empleando técnicas de Machine Learning.

Objetivos Específicos

- Realizar el pre procesamiento de la información que incluya el filtrado, la detección y discriminación de los componentes del sonido cardíaco.
- Determinar los parámetros de entrenamiento óptimos en los métodos de Machine Learning.
- Implementar un algoritmo para la extracción de las características referentes de los sonidos y vibraciones del corazón, para determinar las principales patologías.
- Desarrollar la interfaz gráfica en el PC para el análisis de sonidos cardíacos y detección de anomalías cardíacas utilizando Matlab.

Capítulo II

Estado del Arte

Métodos de medición y análisis de sonidos cardiacos

La evolución de la instrumentación biomédica ofrece nuevos avances para el análisis digital de los sonidos cardiacos, pero aún con el avance tecnológico actual la grabación de sonidos cardiacos se dificulta por factores propios de la fisiología del cuerpo humano, así como factores externos.

La detección de los segmentos se ha abordado desde varias perspectivas, como la de energía a través de la entropía de Shannon que propone (Liang, 1997), que fue de las primeras aproximaciones a una segmentación de sonidos cardiacos, (Kumar, 2007) presenta un algoritmo basado en la transformada Wavelet, sin embargo, este método no pudo detectar los límites de los componentes del sonido cardíaco.

En (Chung, 2007) emplea modelos ocultos de Markov (HMM) estándar que permite establecer un método estocástico doble, y aunque su interpretación es buena este algoritmo no modela los estados de un modo explícito, siendo poco exitoso en la probabilidad de transición de los diferentes estados de un ciclo cardíaco, al no considerarse la duración de los mismos.

Haciendo uso de HMM existen varias investigaciones con distintas modificaciones, con resultados similares al obtenido por (Chung, 2007), y aunque muchos han mejorado la probabilidad de los cambios de estados, no han sido capaces de ser consistentes con las diferentes grabaciones de PCG.

Considerando la importancia de determinar con una alta probabilidad el siguiente estado en la segmentación de sonidos cardiacos (Schmidt, 2008) propone un Modelo

de Markov Oculto Dependiente de la Duración (DHMM), que mejora significativamente la precisión para determinar los segmentos de una señal ECG en la *Tabla 2* se muestra la mejora tanto en sensibilidad como en la predicción de valores positivos.

Tabla 2

Sensibilidad y Valores Predictivos Positivos con DHMM y HMM

Models	Sensitivity	Positive predictive value
DHMM	99.3% (CI: 98.4-99.7%)	99.1% (98.1-99.5%)
HMM	59.5% (CI: 56-63%)	55% (CI:51.6-58.4%)

Nota. Tomado de (Schmidt, 2008), CI: Intervalos de Confianza.

Tomando en cuenta el éxito de la aplicación de DHMM en entornos con ambientes ruidosos, y considerando una menor complejidad en comparación de otros métodos se ha elegido el método aplicado por Schmidt para el presente trabajo.

La Descomposición en Modo Empírico (EMD) de (Boutana, 2011) presentó un método de segmentación de los sonidos cardíacos basado en análisis de frecuencia y tiempo que permite descomponer una señal multicomponente en un conjunto de señales mono componentes, llamadas funciones de modo intrínseco (IMF).

En este método se extrae el coeficiente de correlación para establecer algunas características tiempo-frecuencia que permita distinguir los diferentes segmentos presentes en el ciclo cardíaco.

Una perspectiva diferente se usó por (Tang, 2012) al establecer que los sonidos cardíacos de un ciclo se pueden descomponer en varios átomos caracterizados por el retardo de tiempo, la frecuencia, la amplitud, el ancho de tiempo y la fase. Para segmentar los sonidos cardíacos, los átomos se agrupan en dominios de tiempo-frecuencia y se propone la función de densidad ponderada por energía atómica para mejorar la segmentación de los sonidos cardíacos.

En cada uno de los estudios los principales factores externos que afectan las grabaciones de sonidos del corazón son los ruidos del ambiente, manipulación de instrumentos y movimientos del cuerpo, por lo que la segmentación de una señal de PCG tienen una alta complejidad, para esta segmentación es ampliamente usado el Modelo Oculto de Markov (HMM).

Otro desarrollo basado en energía y aplicando la Transformada S por (Moukadem, 2013) concluyó con aproximaciones cercanas de los sonidos S1 y S2, sin embargo, este método mostraba resultados aceptables solo con sonidos cardíacos normales.

En la búsqueda de la automatización de la segmentación de los FHS se han incluido elementos de estudio como métodos basados en frecuencia - energía como el desarrollado por (Naseri, 2013) que emplea una base sintética para la toma de decisiones combinando las dos características para ser utilizadas como una estadística de decisión de delimitación eficiente (DS).

Posterior a la delimitación se determinaron los extremos locales y las ubicaciones de las pendientes mínimas del DS con aproximaciones hacia adelante y hacia atrás con el propósito de detectar incidencias de sonido y sus límites.

En (Wang, 2020) proponen un algoritmo de segmentación basado en la red adaptable de encuadre temporal (TFAN), que incluye la pérdida de transición de estado y la inferencia dinámica, que no requiere ningún conocimiento previo de la duración del estado de los ruidos cardíacos, por lo tanto, es probable que se generalice al ritmo no sinusal.

Este método obtuvo mejores resultados que los logrados con el modelo semi-Markov oculto de regresión logística (LR-HSMM), sin embargo, utiliza una base de datos menor que la utilizada por esta última, sería importante establecer la comparación de resultados usando el mismo conjunto de datos de validación.

Modelos de Machine Learning aplicados a señales fisiológicas

Los estudios realizados en años recientes demuestran que para una clasificación adecuada de los sonidos cardíacos es importante el acondicionamiento de la señal previo al entrenamiento e implementación de algoritmos de clasificación, aunque no es obligatorio, se recomienda normalizar la señal.

Este acondicionamiento se comprende generalmente de 3 pasos, que comienza con el pre procesamiento, al pasar la señal por una etapa de filtrado, en el siguiente paso se extraen las características que permiten transformar las señales cardíacas en señales de latido de tamaño fijo y finalmente elegir el clasificador adecuado.

De manera general los algoritmos de aprendizaje automático, clasifican nuevos datos a partir de datos o resultados anteriores, para el caso de la clasificación y análisis de señales biomédicas, los algoritmos comúnmente usados son árboles de decisión (DT), bosque aleatorio (RF), el clasificador de vectores de soporte lineal (LSVC).

Dentro del aprendizaje automático se consideran también los métodos de perceptrón multicapa (MLP), la red neuronal recurrente (RNN), y la red neuronal convolucional (CNN).

En (Rubin, 2016) se realiza una transformación de formas de onda unidimensionales en representaciones de mapas térmicos de tiempo-frecuencia bidimensionales utilizando coeficientes cepstrales de frecuencia Mel y redes neuronales convolucionales.

Los espectrogramas constan de 6 coeficientes que capturan las frecuencias Mel se derivan para ventanas deslizantes superpuestas de tres segundos de duración, comenzando en el primer ruido cardíaco, S1.

Una red neuronal convolucional profunda que consta de dos capas alternas de convolución y agrupación máxima se entrena para realizar la extracción automática de características, y un perceptrón multicapa final, que consta de dos capas distingue entre espectrogramas normales y anormales, con especificidad de 93.1% y una sensibilidad de 76.5%.

(Zabihi, 2016) aborda la clasificación de sonidos cardíacos absteniéndose de realizar una etapa de segmentación, esto con 2 propósitos, el primero es comprobar si es necesario segmentar la señal, y el segundo es el de reducir el costo computacional, se eligen de 18 características basadas en un esquema de selección de envoltura.

Las características se extraen de los dominios de tiempo, frecuencia y frecuencia de tiempo sin ninguna segmentación, estas se introducen en un conjunto de 20 redes neuronales de avance para la tarea de clasificación, cuyos resultados son 94,23% de sensibilidad y 88,76% de especificidad.

Otro enfoque para la clasificación de sonidos cardíacos es el uso de un conjunto anidado de algoritmos que incluye Random Forest, LogitBoost y un clasificador sensible a costos como describe (Homsí, 2016), en los que se extrajeron 131 características en el tiempo, la frecuencia, la ondícula y los dominios estadísticos de toda la señal.

Empleando el conjunto anidado de clasificador de conjuntos combinados de características extraídas de diferentes dominios redujo el sobreajuste y mejoró el rendimiento de clasificación al considerar un árbol de decisión elemental, consiguiendo una especificidad del 80,48% y una sensibilidad del 88,48%.

El modelamiento de la dinámica temporal expuesto por (Vernekar, 2016) utiliza el análisis de la cadena de Markov junto con características del dominio de frecuencia y estadísticas entrenadas sobre un conjunto de redes neuronales artificiales y árboles de aumento de gradiente.

De esta manera se consigue una secuencia de símbolos para la señal completa, de donde se crea una matriz de estados y probabilidades de transición, usados como coeficientes ceptrales de frecuencia Mel, los resultados muestran una sensibilidad del 72,9% y una especificidad del 80,9%.

Uno de los trabajos que utiliza Redes Neuronales Convolucionales (CNN) es (Tschannen, 2016), basado en ondas y clasificación por máquina de vectores, incorpora además características fisiológicas y espectrales para resumir las características de toda la grabación de la prueba.

Mientras se alimenta la señal de entrada a través de una secuencia de módulos, cada uno calcula una transformada convolucional, una no linealidad y una operación de agrupación, estas redes extraen características de señal importantes para la

discriminación mientras se suprimen variaciones irrelevantes. En este trabajo se obtuvo una sensibilidad de 84,8% y una especificidad de 77,6%.

Al realizar la comparación de resultados, se aprecia que el método empleado por (Rubin, 2016) alcanza la mayor sensibilidad al combinar el análisis de mapas térmicos a través de los coeficientes cepstrales de frecuencias Mel con la clasificación por redes neuronales convolucionales.

En cuanto a especificidad (Zabihi, 2016) consigue un mejor desempeño, incluso sin considerar una etapa de segmentación en su diseño, lo cuál hace que se requiera menor proceso computacional, en esta propuesta también se emplean redes neuronales para la clasificación de los sonidos.

(Zhang, 2017) propuso el método de clasificación basado en espectrograma escalado y descomposición tensorial. Los espectrogramas de los ciclos cardíacos detectados se escalaron en primer lugar a un tamaño fijo.

Las características más discriminatorias se extrajeron mediante el proceso de reducción de dimensiones de los espectrogramas escalados, y estos mediante el método de descomposición tensorial (MFCC). El algoritmo propuesto se realizó en los conjuntos de datos que fueron obtenidos de Physionet 2016.

En 2018, (Hamidi, 2018) presentó el método de clasificación del sonido cardíaco basado en el ajuste de curvas y la dimensión fractal. La información contenida en la señal del sonido cardíaco se obtuvo mediante el ajuste de curvas, las características útiles que fueron extraídas por MFCC se fusionaron con las características fractales por apilamiento.

El método de clasificación utilizó el clasificador vecino más cercano. Mediante experimentos se logró una precisión global del 81%, 92% y 98% en los tres conjuntos de datos, respectivamente.

(Yaseen, 2018) propuso el método de clasificación del sonido cardíaco basado en múltiples características, la Transformada de Ondas Discretas (DWT) y el Coeficiente Cepstral de Frecuencia Mel (MFCC) se utilizaron para extraer las características de las señales de sonidos del corazón.

Para la clasificación se utilizó la red neuronal profunda (DNN), la máquina de vectores de soporte (SVM) y el desplazamiento de centroide basado en k vecino más cercano, las características de MFCC y DWT se combinaron para mejorar la precisión de la clasificación, el método propuesto se utilizó para diagnosticar las enfermedades cardíacas con una precisión del 97%.

En (Li, 2019) se propone el método de clasificación basado en descomposición Fractal de Wavelet y máquina de vectores de soporte gemelo (TWSVM), en donde la señal original se descompone mediante la transformada de ondículas y se extraen los coeficientes de descomposición de ondículas de la señal.

La dimensión de caja de la señal de sonido cardíaco se resuelve mediante el método de dimensión de caja binaria y se aplica TWSVM para clasificar las señales de los sonidos cardíacos. El algoritmo propuesto obtiene los siguientes resultados: sensibilidad 94,6%, especificidad 85,5%.

El trabajo de (Palani, 2020) propone el uso de arquitecturas de redes neuronales profundas, como una red neuronal convolucional (CNN) y una red neuronal Feed-forward (F-NN) para la clasificación de la señal de fonocardiograma no segmentado

PCG. La señal se re muestrea a 500 Hz y se dividen en segmentos de tiempo más pequeños de 6s.

El modelo F-NN con cinco capas ocultas proporcionó una sensibilidad de 86,7% y una especificidad de 84,7%, considerando la ausencia de procesos de segmentación.

Otra propuesta combinada entre redes neuronales profundas (DNN) y transformada de ondas empíricas de Wavelet (EWT) se implementa en (BABU, 2020), la técnica de procesamiento de señales convencional se basa en EWT, que diseña de manera adaptativa los bancos de filtros en función del tipo de interferencia.

El método realiza la segmentación de PCG usando EWT y el reconocimiento de FHS usando DNN basado en U-Net. Las características de la envolvente se extraen de la señal reconstruida basada en EWT y se utilizan para entrenar el DNN basado en U-Net para que reconozca FHSS, el trabajo propuesto basado en U-Net con el método EWT logra una precisión de reconocimiento de FHS del 91,17%.

En la *Tabla 3* se muestra un resumen de los resultados obtenidos en cada uno de los trabajos investigados.

Tabla 3

Comparación de los Resultados de Trabajos Similares

Autor	Sensibilidad	Especificidad	Promedio
Rubin	93.1%	76.5%	84,8%
Zabihi	88.76%	94.23%	91,5%
Homsy	80.48%	88.48%	84,48%

Vernekar	80.9%	72.9%	76,9%
Tschannen	77.6%	84.8%	81,2

Considerando los resultados obtenidos de investigaciones anteriores, se propone en el presente proyecto la implementación de una etapa de segmentación robusta y de menor complejidad a través de HSMM, y una clasificación con redes neuronales convencionales.

Fundamentos Teóricos

Señales FCG/PCG

El corazón es un órgano muy importante en los seres vivos, y por supuesto en los seres humanos, al que la ciencia y la tecnología han dedicado un gran esfuerzo en entender su funcionamiento, por lo que su estudio se establece desde diferentes percepciones, como el de sus biopotenciales eléctricos, o el de su funcionamiento mecánico.

Para entender la actividad eléctrica del corazón se realiza un electrocardiograma (ECG), que permite captar los impulsos eléctricos generados por el músculo cardíaco a través de electrodos fijados en zonas específicas del cuerpo que registra las variaciones de voltaje a lo largo del tiempo, estas variaciones se conocen como derivaciones de ECG, que se pueden visualizar de manera simultánea.

El funcionamiento mecánico del corazón está dado principalmente por la acción de las válvulas cardíacas que conducen el flujo de la sangre por el sistema circulatorio, estas válvulas se ubican dentro de cavidades llamadas cámaras, los sonidos cardíacos

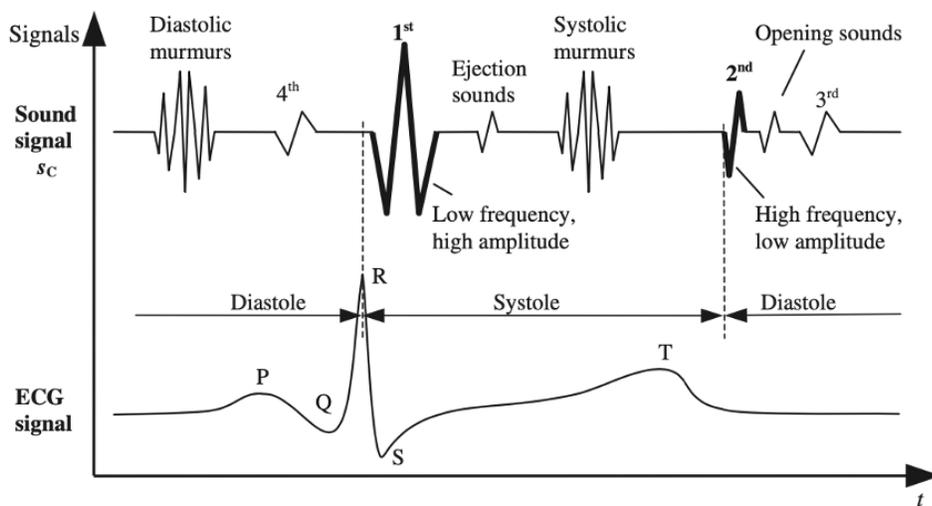
se producen en la interacción de las válvulas al cerrarse creando vibraciones mecánicas que se captan como sonidos.

El fonocardiograma permite registrar los sonidos cardíacos entendidos como señales bio acústicas, representadas gráficamente a través del tiempo, de las cuales se pueden determinar la frecuencia, la intensidad y los componentes del sonido cardíaco.

En la *Figura 1* se muestra la representación de una señal de ECG con su correspondiente señal de fonocardiograma (PCG).

Figura 1

Representación de una Señal ECG y una Señal PCG



Nota. Tomado de (Kaniusas, 2017)

Aunque el ECG y el PCG se estudian desde diferentes perspectivas es importante entender la relación entre las mismas, pues en muchos de los casos el diagnóstico requiere de la evaluación integral de las señales acústicas y eléctricas en el ciclo cardíaco.

Una señal de PCG está constituida principalmente por “sonidos” y “silencios”, los “sonidos” son los picos de mayor amplitud que registra la señal, mientras que los “silencios” se interpretan como los espacios entre cada uno de los sonidos, sin que se consideren como ausencias de señal.

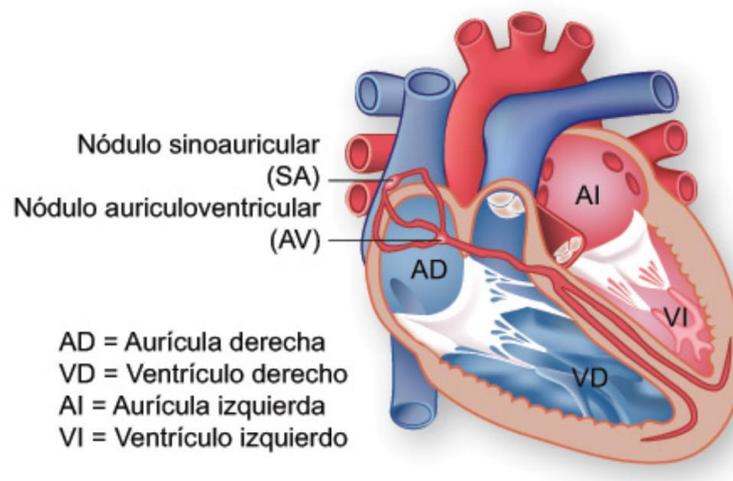
Anatomía de las válvulas y cavidades cardíacas

El corazón se compone de cuatro cavidades denominadas cámaras, dos superiores y dos inferiores que son como se muestra en la *Figura 2*, las aurículas se encuentran en la parte superior, y los ventrículos en la parte inferior:

- Aurícula derecha,
- Aurícula izquierda
- Ventrículo derecho
- Ventrículo izquierdo

Figura 2

Cavidades Cardíacas



Notas. Tomado de (El sistema de conducción, SF)

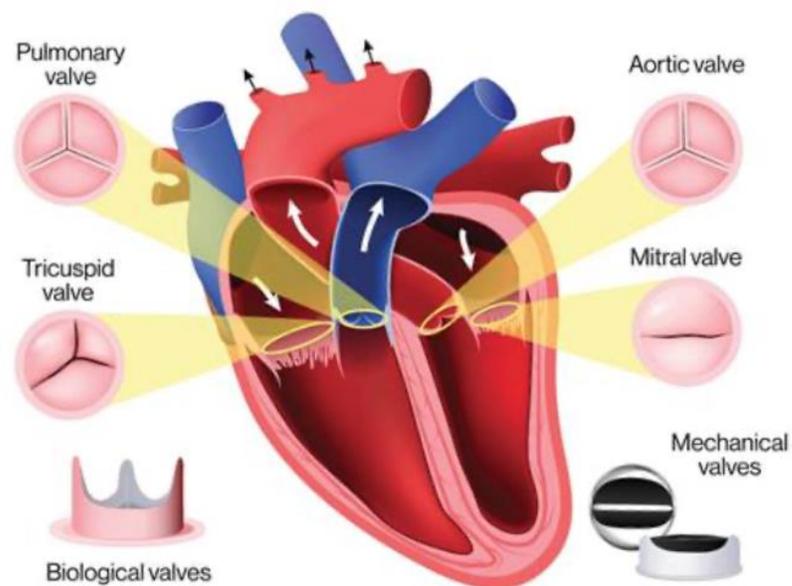
Dentro de estas cavidades se encuentran las válvulas que permiten el flujo continuo y unidireccional de la sangre a través del sistema circulatorio que se muestra en la *Figura 3* y son:

- Válvula tricúspide: se encuentra entre el ventrículo y aurícula derecha
- Válvula mitral: se encuentra entre el ventrículo y aurícula izquierda
- Válvula pulmonar: se encuentra entre el ventrículo derecho y la arteria pulmonar
- Válvula aórtica: se encuentra entre el ventrículo izquierdo

Tanto las cavidades como las válvulas cardíacas permiten el flujo de la sangre por la contracción y relajación de los músculos cardíacos constituidos por fibras musculares y que, junto con los vasos sanguíneos, las venas y las arterias forman el sistema cardiovascular.

Figura 3

Cavidades y Válvulas del Corazón



Nota. Tomado de (Anatomía del Corazón, SF)

Funcionamiento de las válvulas cardíacas

De manera general, el corazón bombea sangre con poco oxígeno a través del sistema circulatorio hacia los pulmones, estos proporcionan oxígeno a la sangre que pasa por el corazón para distribuirlo nuevamente al cuerpo, en este proceso las válvulas se abren y cierran, permitiendo el paso de la sangre en una dirección y evitando que regrese.

El sistema de válvulas que posee el corazón debe estar sincronizado para un flujo continuo y constante de sangre oxigenada, en el lado derecho del corazón la válvula tricúspide se abre y permite pasar sangre de la aurícula al ventrículo, una vez lleno el ventrículo la válvula tricúspide se cierra, entonces la válvula pulmonar se abre para que la sangre del ventrículo salga hacia los pulmones para recibir oxígeno.

En el lado izquierdo de manera similar, la válvula mitral se abre para permitir el flujo de sangre desde la aurícula hacia el ventrículo, una vez lleno el ventrículo la válvula mitral se cierra para evitar reflujo y entonces se abre la válvula aórtica para que la sangre del ventrículo rica en oxígeno se distribuya al sistema circulatorio, como se muestra en la *Figura 4*.

Ciclo cardíaco

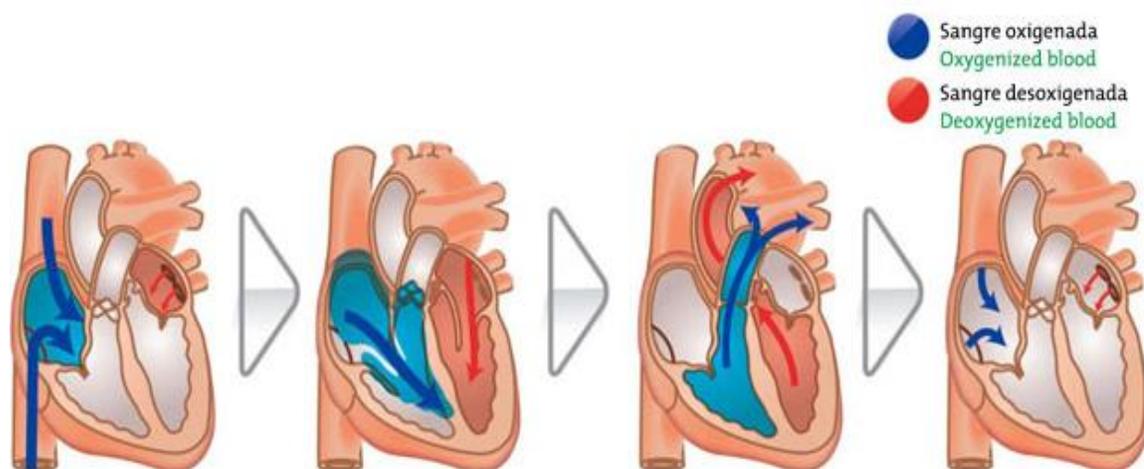
Se define al ciclo cardíaco como una secuencia de eventos periódicos comprendidos por la contracción y relajación alternadas de las cavidades cardíacas para bombear sangre por el sistema circulatorio a todo el cuerpo, la etapa de contracción se denomina sístole, y la etapa de relajación, diástole.

En la fase sistólica los ventrículos se contraen y las válvulas aórtica y pulmonar se abren para permitir el paso de la sangre hacia la aorta y la arteria pulmonar, mientras

que las válvulas auro ventriculares se cierran, evitando así que la sangre llegué a los ventrículos.

Figura 4

Funcionamiento de las Válvulas Cardíacas



Nota. Tomado de (El Corazón, SF)

En la fase diastólica la aurícula izquierda recibe sangre oxigenada de los pulmones y lo envía hacia los ventrículos, de tal manera que el ciclo cardíaco representa los cambios hemodinámicos y eléctricos que ocurren en la sístole y en la diástole. (Ali, 2020)

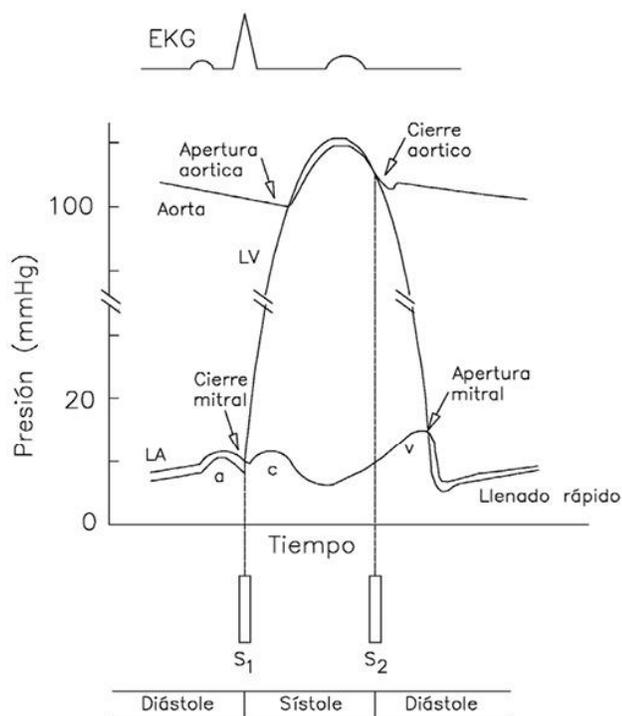
Las fases del ciclo cardíaco se muestran en la *Figura 5* con las correspondientes aperturas y cierres de las válvulas aórtica y mitral en función de la presión del flujo de sangre y el tiempo de llenado de las cavidades cardíacas, en la parte inferior de la gráfica se observa la identificación de los sonidos cardíacos fundamentales (FHS), ubicados entre la sístole y la diástole.

Sonidos Cardíacos

Los sonidos de la actividad cardíaca son generados por el flujo sanguíneo cuyas vibraciones en válvulas y cavidades son perceptibles por determinados transductores, incluso por el oído humano, estos sonidos varían por diferentes factores, como el diámetro del vaso sanguíneo, la velocidad del flujo de sangre, su densidad o viscosidad, entre otros. (William, 2020).

Figura 5

Fases del Ciclo Cardíaco



Nota. Tomado de (Tamariz, 2016)

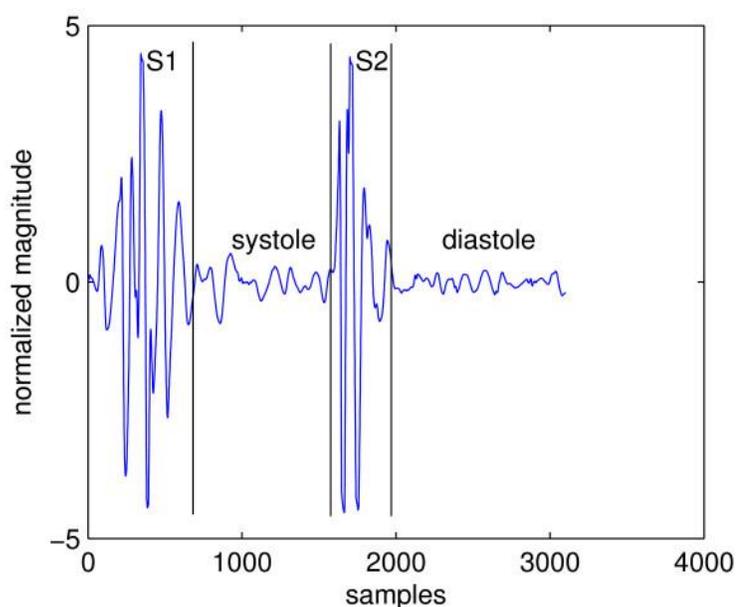
Se consideran sonidos cardíacos fundamentales a los sonidos más audibles de un ciclo cardíaco, reconocidos como S1 y S2 y asociados de manera acústica y

convencional como “lup” y “dup” respectivamente, lo cual permite familiarizar al oído humano con el ritmo del corazón.

S1 se genera al iniciarse la contracción ventricular y se caracteriza por tener una duración entre 100ms a 200ms y ubicarse en el rango de frecuencias de 25 a 45Hz. S2 se ubica al final de la sístole ventricular con una duración aproximada 120ms inferior a los 150Hz. En la *Figura 6* se muestran lo FHS S1 y S2 de una señal PCG normal.

Figura 6

Sonidos Fundamentales S1 y S2



Nota. Tomado de (Yuenyong, 2011)

Los sonidos S1 y S2 se consideran fundamentales, porque son sonidos fisiológicos del ser humano, sin embargo, se pueden registrar algunos otros, que pueden estar asociados a patologías o componentes de ruido que se inducen por fuentes externas, como la manipulación de los instrumentos de adquisición, ruido

ambiental, ruido generado por otros órganos del cuerpo o movimientos del sujeto, entre otros.

Otros sonidos considerados determinantes en algunos casos son S3 y S4, el sonido S3 se registra cuando una considerable cantidad de sangre choca con las paredes de la cámara ventricular, este sonido en el caso de niños generalmente es normal, pero en personas adultas se considera como un sonido patológico que requiere de un análisis más profundo, en la *Figura 7* se muestra los sonidos S3 y S4 en la etapa diastólica.

En el caso de S4, cuando se presenta, siempre se considera como patológico y se produce cuando la sangre choca con un ventrículo dilatado, y con poca movilidad ya sea por un proceso infiltrativo o inflamatorio.

En la *Tabla 4* se muestra un resumen de la etapa en la que se producen cada uno de los sonidos cardíacos, fisiológicos S1 y S2, y patológicos S3 y S4 y el funcionamiento mecánico asociados a los mismos.

Tabla 4

Principales Sonidos Fisiológicos y Patológicos

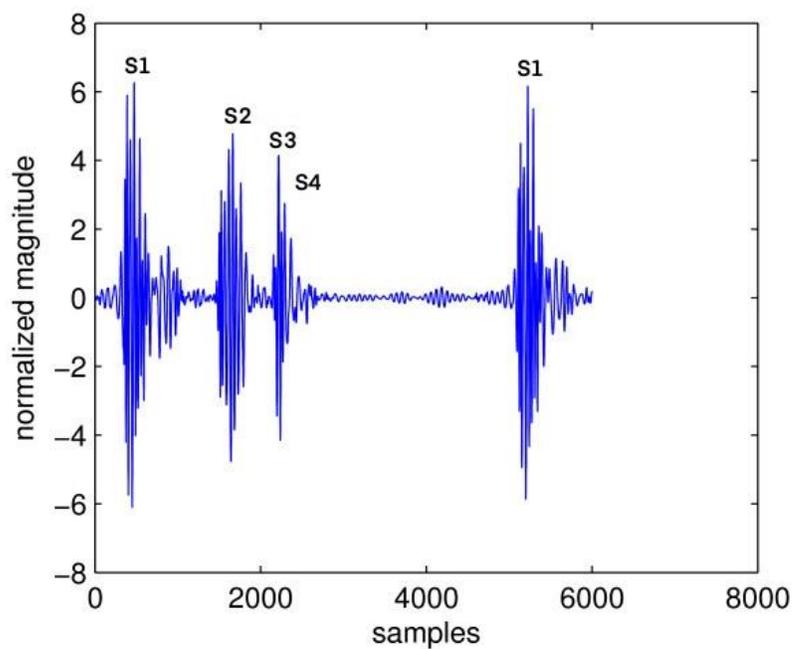
Sonido cardíaco	Ocurre durante:	Asociado con:
S1	Contracción isovolumétrica	Cierre de válvulas mitral y tricúspide.
S2	Relajación isovolumétrica	Cierre de válvulas aórtica y pulmonar.

Sonido cardíaco	Ocurre durante:	Asociado con:
S3	Llenado ventricular temprano	Normal en niños; en adultos, asociado con dilatación ventricular (por ejemplo, insuficiencia sistólica ventricular)
S4	Contracción auricular	Asociado con ventrículo rígido y poco dócil (p. Ej., Hipertrofia ventricular; ventrículo isquémico)

Nota. Tomado de (Klabunde, 2015)

Figura 7

Sonidos S3 y S4



Nota. Tomado de (Yuenyong, 2011)

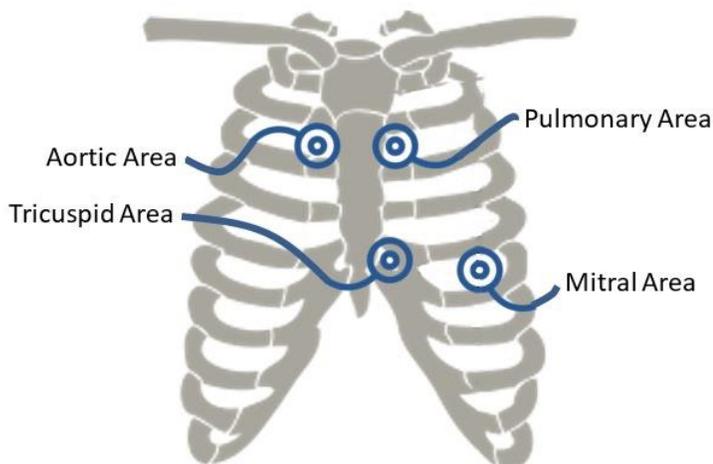
Auscultación de sonidos cardíacos

La auscultación del corazón se realiza a través de un estetoscopio que permite captar los sonidos del corazón a través de una campana o diafragma, conducido a unos auriculares que permiten escuchar la actividad cardíaca, en la actualidad existen estetoscopios electrónicos que tienen la capacidad de almacenar las grabaciones de los sonidos, para un procesamiento posterior.

Para un adecuado diagnóstico se requiere que el instrumento de adquisición se ubique en el lugar adecuado del cuerpo humano para captar el mayor espectro audible, y conforme los procedimientos clínicos se han determinado 4 áreas de auscultación cardíaca, como se muestra en la *Figura 8*, que son: *mitral, pulmonar, tricuspídea y aórtica*.

Figura 8

Áreas de Auscultación



Nota. Tomado de (Vinay, 2020)

Aunque los instrumentos de auscultación han evolucionado se requiere de un oído entrenado y pericia para determinar un diagnóstico apropiado, de tal manera que se pueda distinguir las sutiles diferencias de los diferentes tono y frecuencias registrados a través de un estetoscopio.

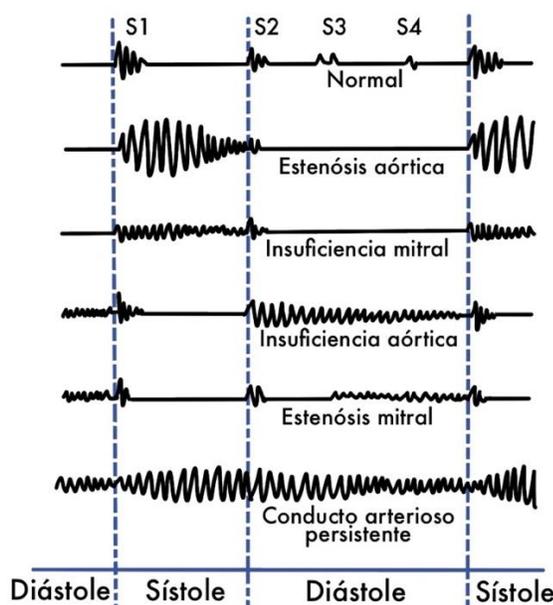
Soplos cardíacos

Se consideran soplos cardíacos a los sonidos que se generan en el corazón, vasos sanguíneos y por el flujo turbulento de sangre en intervalos silenciosos en un ciclo cardíaco normal y que no forman parte de los FHS, estos sonidos adicionales se pueden presentar en las fases sistólica, diastólica o de manera continua.

En la *Figura 9* se muestran los distintos soplos de acuerdo a su ubicación dentro del ciclo cardíaco, asociados a un funcionamiento anómalo de las válvulas cardíacas, conocidas como valvulopatías.

Figura 9

Soplos en las Fases del Ciclo Cardíaco



Los soplos que se aprecian en la sístole son tanto patológicos como fisiológicos, y de acuerdo con su ubicación en la etapa pueden ser tempranos, medios o tardíos. En el caso de los soplos diastólicos, estos siempre se consideran patológicos que se generan principalmente por una insuficiencia valvular.

En el caso de los soplos continuos, su validación siempre se debe acompañar de los antecedentes de la persona ya que se inducen sonidos continuos en casos de embarazo, lactancia, hipertiroidismo o anemia.

Valvulopatías

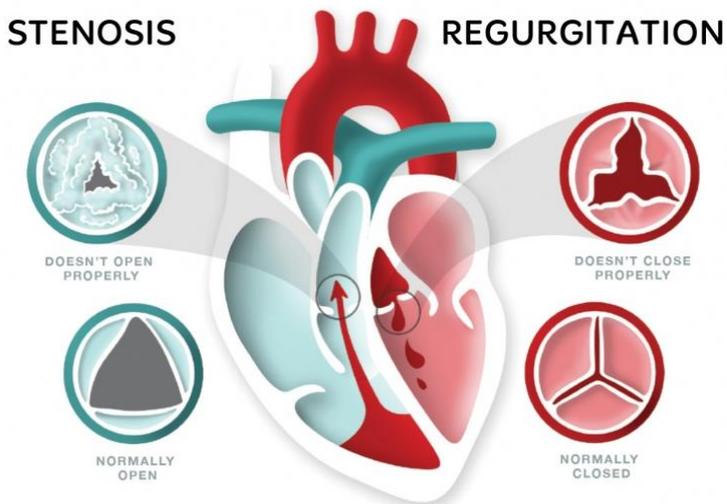
Las valvulopatías son el conjunto de enfermedades relacionadas al mal funcionamiento de una o más válvulas cardíacas, las cuales se abren y cierran para permitir el flujo de sangre en un sentido, y evitan que regrese en el sentido contrario.

La apertura o cierre inadecuado de estas válvulas alteran el flujo de sangre entre las cavidades auriculares, ventriculares y las arterias pulmonar y aorta, generando daños a mediano y largo plazo. Las valvulopatías pueden ser congénitas o desarrollarse a lo largo del tiempo, en la *Figura 10* se muestran las valvas de las válvulas cardíacas cuando no abren o cierran de manera correcta.

Las principales valvulopatías y de mayor impacto a nivel mundial son la insuficiencia y la estenosis. La insuficiencia se produce cuando las valvas o aletas de las válvulas no se cierran lo suficiente como para impedir que la sangre regrese en sentido opuesto al flujo de la sangre, y la estenosis se produce por una rigidez de las valvas que evita una apertura adecuada, que genera un flujo reducido de sangre.

Figura 10

Principales Valvulopatías: Insuficiencia y Estenosis



Nota. Tomado de (Heart Foundation, SF)

Redes Neuronales Convolucionales

Las redes neuronales convolucionales forman parte de los métodos de aprendizaje profundo, y estos a su vez del conjunto de métodos de aprendizaje automático o machine learning. Las CNN intentan modelar la abstracción de datos a gran escala dando así sentido a datos como imágenes, sonidos y textos, entre otros.

Las CNN toman de referencia al funcionamiento de la corteza visual del ser humano que consiste en mapas de campos receptivos locales que responden a los estímulos únicamente en una región del campo visual, y disminuyen a medida que la corteza se mueve hacia adelante. Estos campos receptivos se superponen de modo que cubren todo el campo visual.

Cada neurona solo se encuentra conectada a un parche local de neuronas de la siguiente capa, la arquitectura de las CNN se define en un patrón jerárquico de los

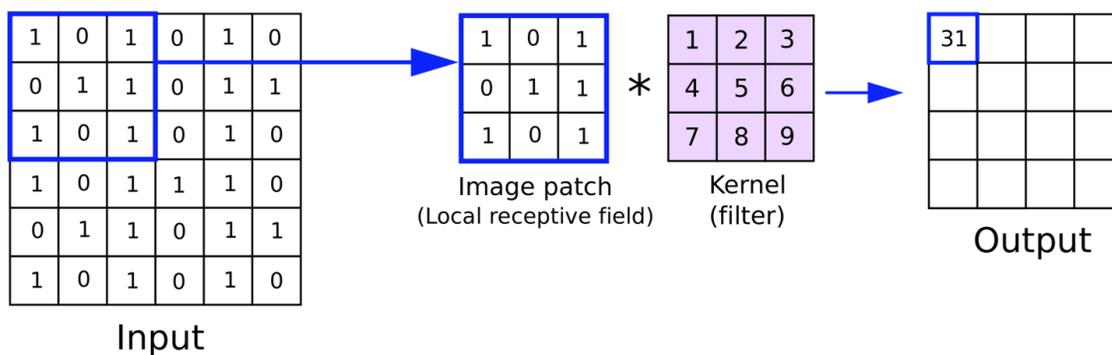
datos para ensamblar patrones más complejos usando unos patrones más pequeños y simples.

La red usa el operador matemático conocido como convolución, el cual permite realizar operaciones complejas de forma más sencilla. Los datos de la capa de entrada son convolucionados por diferentes filtros convolucionales durante el desplazamiento a través de las neuronas. Los filtros convolucionales comparten los mismos parámetros en cada pequeña porción la red, reduciendo los parámetros del algoritmo.

Para aplicaciones de series de tiempo, como datos de audio, por otro lado, es necesario el uso de filtros fijo a los datos unidimensionales sin procesar para generar una representación de características. En la *Figura 11* se muestra un ejemplo de filtro en una CNN.

Figura 11

Aplicación de Filtros a una Capa de Entrada



Nota. Tomado de (Reynolds, 2019)

El aprendizaje profundo en general tiene dos propiedades:

- Múltiples capas de unidades de procesamiento no lineales.

- Aprendizaje supervisado o no supervisado de presentaciones de características en cada capa.

Funciones de activación: Las funciones de activación forman las capas no lineales en las redes aprendizaje profundo y sus combinaciones con otras capas se utilizan para simular la transformación no lineal de la entrada a la salida.

Las CNN son capaces de clasificar el espacio muestral no lineal, solo por las funciones de activación, si no hay una función de activación, todas las capas se pueden contraer en una sola capa.

Las principales funciones de activación usadas en aplicaciones biomédicas son: función sigmoidea, tangente hiperbólica y ReLu.

Función sigmoidea: donde a es la entrada de la capa frontal, la función sigmoidea transforma variables a valores que van de 0 a 1 y se usa comúnmente para producir una distribución de Bernoulli, ejemplo:

$$g(a) = \frac{1}{1+e^a}, \text{ Función sigmoidea}$$

$$\tilde{g} = \begin{cases} 0 & \text{si } g(a) \leq 0,5 \\ 1 & \text{si } g(a) > 0,5 \end{cases}, \text{ Ejemplo de aplicación}$$

Unidad Lineal Rectificada (ReLu): $g(a) = \max(0, a)$

Los filtros ayudan a identificar las diferentes características presentes en la señal, luego se aplica la agrupación sobre los mapas de características que permite que, al cambiar la entrada en una pequeña cantidad, las salidas agrupadas no cambian.

Una red neuronal convolucional básica consta de: capa de entrada, capa de convolución, y capa de salida.

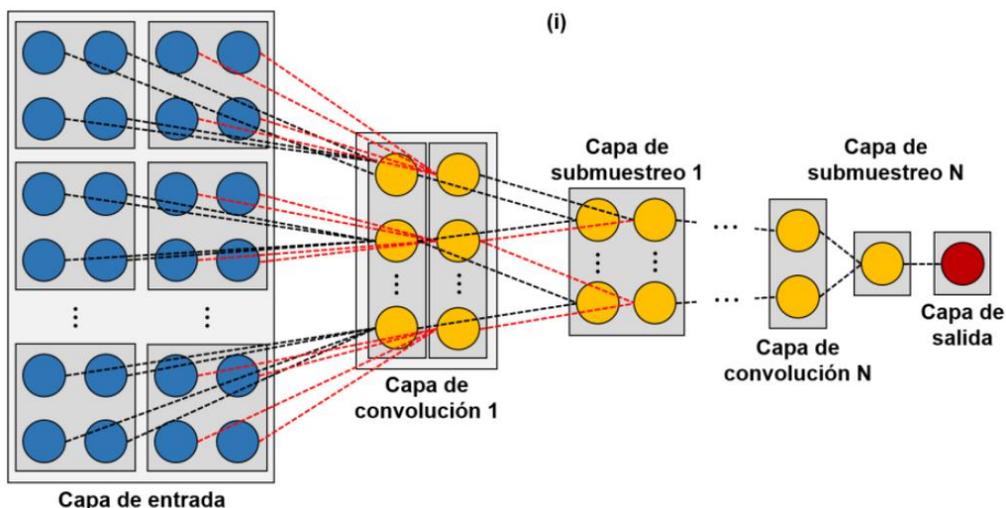
La capa de entrada contiene la información en bruto o también información pre procesada en algunos casos que requieren eliminación de ruido o de componentes no deseables que afecten la extracción posterior de características.

La capa de convolución contiene los filtros o kernels que permitirán extraer las características de la información de entrada, una función de activación y una operación de agrupación máxima, que simplifica las capas de salida.

En la *Figura 12* se muestra un ejemplo de una CNN con las tres capas principales, dependiendo de la necesidad del algoritmo se pueden incluir capas intermedias entre cada capa de convolución.

Figura 12

Ejemplo de capas de convolución



Nota. Tomado de (Sarmiento, 2019)

Capítulo III

Desarrollo del algoritmo de detección y clasificación de arritmias

Introducción

De acuerdo al objetivo planteado se ha determinado que el sistema de detección de valvulopatías tendrá las características siguientes:

- Capacidad de filtrar y eliminar ruido
- Capacidad de segmentar
- Manejo de redes neuronales para aprendizaje automático
- Aprendizaje de la red neuronal con 114 registros cardiológicos de audio del subconjunto “f” de pruebas de la base de datos de Physionet.
- Capacidad de realizar el diagnóstico de registros cardíacos de audio con una duración mínima de 10 segundos y muestreados a 2000Hz.
- Almacenar el registro procesado con el diagnóstico obtenido por el algoritmo.

Para el presente proyecto se utilizó la base de datos disponible en Physionet cuyos registros provienen de las grabaciones de sonidos cardíacos recopiladas tanto en entornos clínicos y no clínicos, en pacientes sanos y pacientes que han sido diagnosticados con alguna afección de las válvulas cardíacas.

Esta base de datos cuenta con subconjuntos de registros para entrenamiento y validación, la duración de las grabaciones, así como la frecuencia de muestreo de cada adquisición son diferentes en cada caso, debido a los instrumentos utilizados, de tal manera que para que sea un conjunto homogéneo todas las grabaciones han sido re muestreadas a 2000Hz y exportadas en formato de sonido .wav por parte de Physionet.

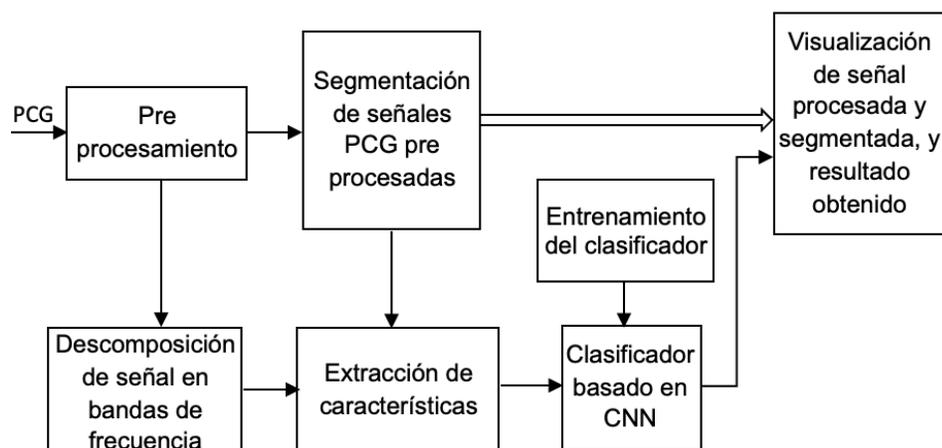
Las grabaciones de las bases de datos no se encuentran balanceadas, ya que el número de registros de pacientes sanos es diferente al de pacientes con valvulopatías, y no se especifica la edad o sexo del paciente en las etiquetas de los datos, entre otros, teniendo únicamente etiquetas de tipo “normal” o “anormal” en cada una de las grabaciones de PCG.

Diagrama de bloques del sistema

En la Figura 13 se muestra el diagrama de bloques del sistema de detección de valvulopatías cuya entrada es la señal de audio en formato .wav muestreada a 2000Hz que ingresa a la etapa de pre procesamiento, en donde se realiza un filtrado y eliminación de picos de amplitud.

Figura 13

Diagrama de Bloques para la Detección de Valvulopatías



Una vez adecuada la señal, esta pasa por dos etapas que permiten extraer sus características, la primera es la segmentación, que permite identificar los segmentos S1, S2, Sístole y Diástole, y la segunda etapa en la que la señal se descompone en 4 bandas de frecuencia que junto con la primera permiten determinar los ciclos cardíacos,

que forman parte de las características de la señal de entrada al proceso de clasificación, en el algoritmo de redes neuronales convolucionales.

Al procesarse la señal por el algoritmo de detección de valvulopatías se muestra la gráfica de la señal procesada, la segmentación y el resultado del diagnóstico proporcionado por el clasificador basado en CNN.

Etapa de pre procesamiento

La etapa de pre procesamiento consiste en adecuar las señales de audio obtenidas de la base de datos de Physionet, previo a la etapa de segmentación y descomposición de las mismas.

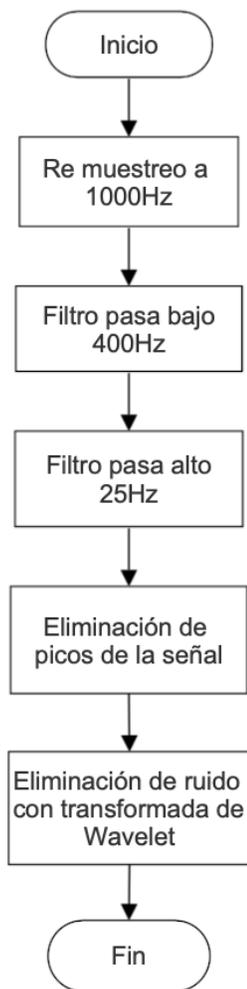
En la Figura 14 se muestra el diagrama de flujo del pre procesamiento de la señal, que inicia con la normalización de las señales realizando un re muestreo a 1000Hz, que permite distinguir mejor los “sonidos” y “silencios” de los registros fono cardiográficos.

En la *Figura 15* se muestra la señal normalizada, superpuesta a la señal original, es importante la normalización de la señal original, ya que permite distinguir los picos de los sonidos principales de sonidos adyacentes que no forman parte de los FHS.

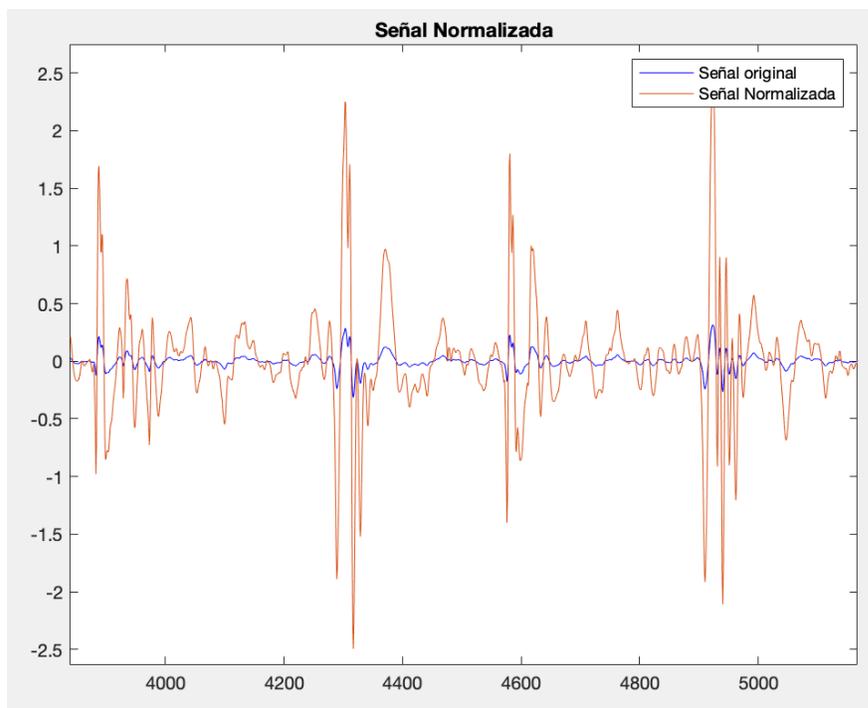
Al realizar la normalización la señal se escala a un nivel que permite llevar el pico de la señal promedio a un objetivo mediante la aplicación de una constante, al normalizar se escala tanto la señal cardíaca como el ruido presente en la misma, aunque la relación señal / ruido se mantiene.

Figura 14

Diagrama de Pre Procesamiento de Señales PCG



Una vez normalizados los registros se procede con la implementación de filtros, primero por un filtro pasa bajo de Butterworth de 400 Hz y luego por un filtro pasa alto de Butterworth de 25 Hz de segundo orden, de esta manera se realzan los sonidos S1 y S2, considerando que el rango de frecuencias típico de los sonidos cardíacos se encuentra entre 10 – 200 Hz y ciertas afecciones de las válvulas cardíacas, cumpliendo así con el teorema de Nyquist – Shannon.

Figura 15*Señal PCG Normalizada*

Posterior al filtrado se realiza la eliminación de los picos de la señal, proceso en el que se divide la señal en ventanas de 500ms y se determina la amplitud máxima en cada una, en el caso que una de las amplitudes exceda tres veces su valor mediano se identifica la ventana a la que corresponde y se ubica la amplitud absoluta máxima como la parte superior del pico de ruido.

Para eliminar el ruido que se induce por la manipulación de los equipos de adquisición en la captación de las grabaciones de PCG, se utiliza la transformada de Wavelet que permite descomponer la señal filtrada en determinados coeficientes, los mismos que se modifican a través de un umbral, a estos coeficientes modificados se los reconstruye para formar una señal de salida con reducción de ruido.

Para implementar esta etapa de pre procesamiento se ha generado el código que se muestra en la Figura 16.

Figura 16

Código de Matlab de Pre Procesamiento de la Señal

```

%% Cargar las grabaciones de PCG
[app.signal_name, app.path_file] = uigetfile({'*.wav'}, 'File Selector');
if ~app.signal_name
    return
end

%% Almacenar las muestras y la frecuencia de muestreo
[data, fs] = audioread(strcat(app.path_file, app.signal_name));
if length(data) > 6*fs
    data = data(1:6*fs); %almacenar las primeras 60*2000=120000 muestras
end

% Re muestreo a 1000 Hz
app.PCG_resampled = resample(data,1000,fs);

% Normalizar la señal PCG original
base_signal = app.PCG_resampled * 0.5 / rms(app.PCG_resampled);

% Grafica de la señal original vs la señal normalizada
plot(app.PCG_resampled,'b')
hold("on")
plot(base_signal)
title('Señal Normalizada')
legend('Señal original', 'Señal Normalizada')

% Filtrar la señal en un rango de 25 a 400 Hz
app.PCG_resampled = butterworth_low_pass_filter(app.PCG_resampled, 2, ...
    400, 1000, false);
app.PCG_resampled = butterworth_high_pass_filter(app.PCG_resampled, 2, ...
    25, 1000, false);

% Quitar picos
app.PCG_resampled = schmidt_spike_removal(app.PCG_resampled, 1000);

% Transformada de wavelet para eliminar ruido
data_w = app.PCG_resampled * 0.5 / rms(app.PCG_resampled);
[c, l] = wavedec(data_w, 3, 'db1');
b = wthresh(c, 's', 0.1);
app.filtered_data = waverec(b, l, 'db1');
app.filtered_data = app.filtered_data * 0.5 / rms(app.filtered_data);

%Grafica señal original vs señal filtrada
app.UIAxes_1.reset;
plot(app.UIAxes_1, base_signal, 'b')
hold(app.UIAxes_1, 'on' )
plot(app.UIAxes_1, app.filtered_data)
legend(app.UIAxes_1, 'Señal original', 'Señal filtrada')
app.UIAxes_1.Title.String = strcat('Señal pre procesada ("...
    ,app.signal_name, "')');
hold(app.UIAxes_1, 'off' )

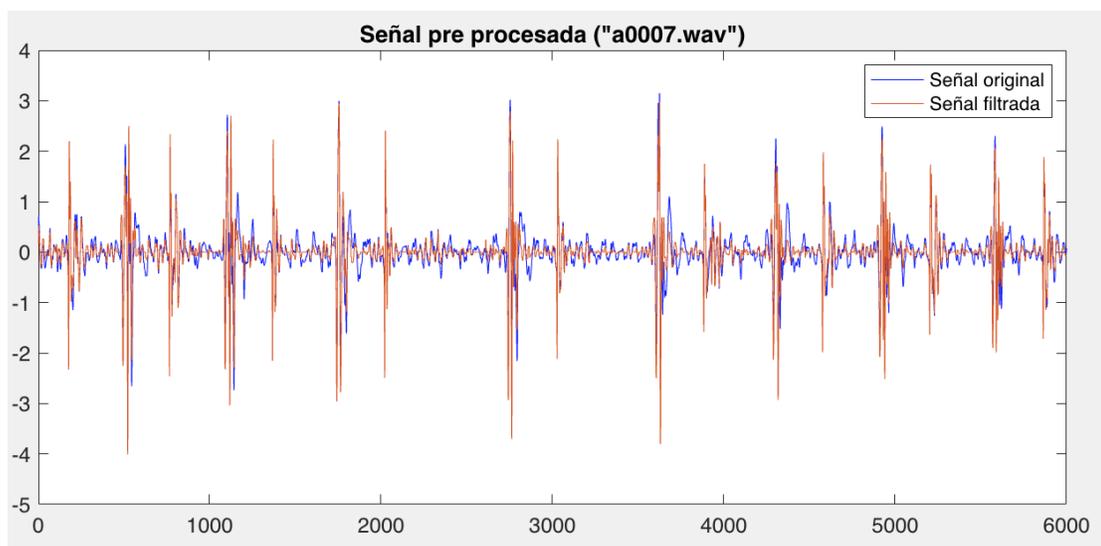
```

Nota. Código que incluye las etapas de filtrado, eliminación picos y eliminación de ruido.

Al ejecutar el código en Matlab con la señal de prueba a0007.wav se obtiene la señal pre procesada, como se indica en la Figura 17, en donde se muestra la señal original y la señal filtrada.

Figura 17

Gráfica de la Señal Original vs la Señal Filtrada



Nota. La señal de prueba a0007.wav corresponde a la grabación de un paciente sano.

Segmentación de señales pre procesadas

Para la segmentación se ha realizado el procedimiento de (Springer, 2016) el cual usa HSMM, ampliando sus capacidades al usar regresión logística para una mejor estimación de la probabilidad, lo cual ha demostrado que es un modelo preciso que permite la segmentación del primer y segundo sonido cardíaco y sus correspondientes etapas, sistólica y diastólica en entornos ruidosos.

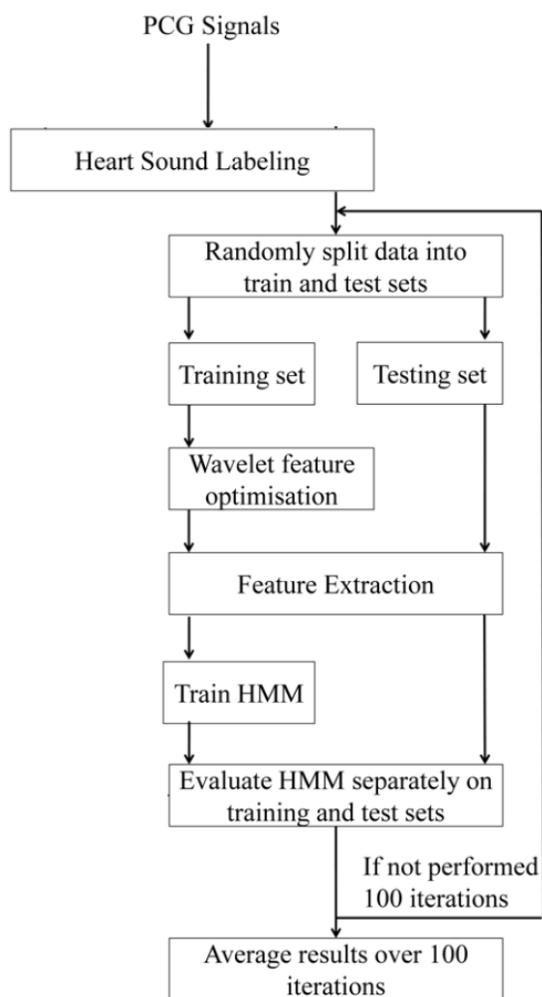
En (Springer, 2016) se implementa un algoritmo modificado de Viterbi que decodifica la secuencia de estados más probable, de esta manera se resuelve la

necesidad de que los estados comiencen y terminen al inicio y fin de la señal PCG respectivamente, y permite extenderse tanto al inicio como al final de la señal.

En la Figura 18 se muestra el diagrama de bloques para la implementación de la segmentación de una señal PCG, previamente filtrada.

Figura 18

Diagrama de Bloques del Algoritmo de Segmentación



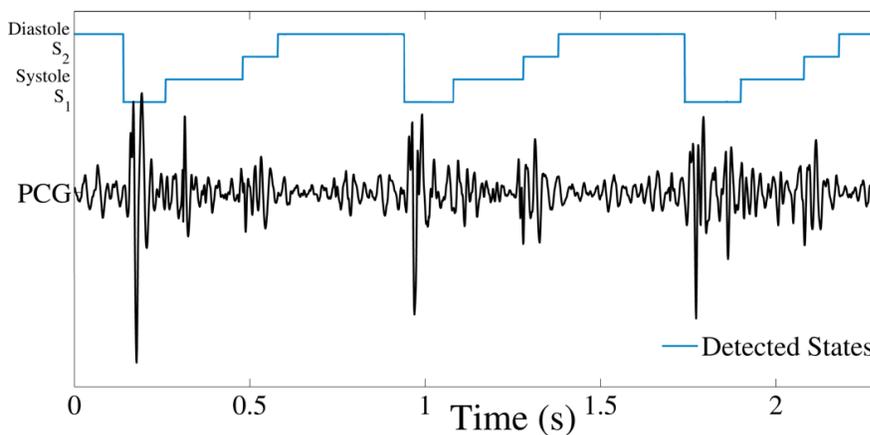
Nota. Tomado de (Springer, 2016)

El procedimiento usado por (Springer, 2016) además de las grabaciones de PCG utiliza los registros de ECG, sin embargo, en el presente proyecto se ha considerado el enfoque exclusivo en el análisis de las grabaciones de los sonidos cardíacos, de tal manera que existen modificaciones a su método.

En la Figura 19 se observa una señal de PCG y la correspondiente identificación de cada uno de los segmentos asociados a las etapas del ciclo cardíaco en relación al funcionamiento de las válvulas del corazón y sus sonidos característicos. Donde en el segmento S1 se encuentran los picos del sonido “Lup” seguido de un segmento de silencio que representa la sístole, luego en el segmento S2 se encuentran los picos del sonido “Dup”, seguido de un segmento de silencio que representa la diástole.

Figura 19

Segmentos S1, S2, Sístole y Diástole Identificados



Nota. Tomado de (Springer, 2016)

Los modelos de semi Markov ocultos permiten determinar datos secuenciales, que realizan inferencias sobre la probabilidad de estar en ciertos “estados ocultos”

discretos, moviéndose entre esos estados. Para el presente trabajo los estados son: (S1, sístole, S2, diástole), mientras que la secuencia observada es la señal PCG.

Para la implementación del algoritmo entrenado de segmentación se hace uso de los siguientes coeficientes:

- B_matrix: la matriz de observación para el HSMM
- pi_vector: la distribución de estado inicial
- Total_observation_distribution, las probabilidades de observación

Como entrada se requiere de la señal de PCG y la frecuencia de muestreo, el código de la implementación del algoritmo de segmentación se muestra en Figura 20.

Figura 20

Código de Matlab para Implementar el Algoritmo de Segmentación

```

%% Get PCG Features:
[PCG_Features, featuresFs] = getSpringerPCGFeatures(audio_data, Fs);

%% Get PCG heart rate
[heartRate, systolicTimeInterval] = getHeartRateSchmidt(audio_data, Fs);

[~, ~, qt] = viterbiDecodePCG_Springer(PCG_Features, pi_vector, B_matrix, ...
total_observation_distribution, heartRate, systolicTimeInterval, featuresFs);

assigned_states = expand_qt(qt, featuresFs, Fs, length(audio_data));
t1 = (1:length(audio_data))./Fs;
norm_sig = normalise_signal(audio_data);

if(figures)
    figure('Name','Derived state sequence');
    plot(t1,norm_sig,'k');
    hold on;
    plot(t1,assigned_states,'r--');
    legend('Audio data', 'Derived states');
end

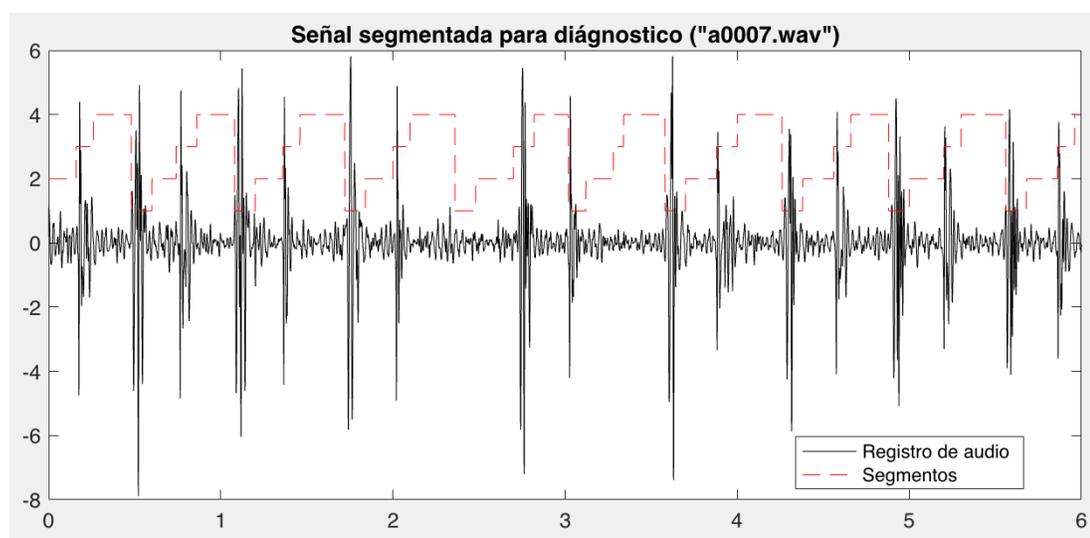
```

Nota. Tomado de (Springer, 2016).

En la Figura 21 se muestra la implementación del algoritmo de segmentación a la señal de prueba a0007.wav y se puede observar la señal de PCG con la identificación de los segmentos sobrepuesta, los picos de la señal se identifican como los sonidos fundamentales S1 y S2, mientras que los “silencios” corresponden a la sístole y a la diástole, de abajo para arriba se tienen como niveles: S1, sístole, S2, diástole.

Figura 21

Gráfica de la Identificación de Segmentos en la Señal PCG



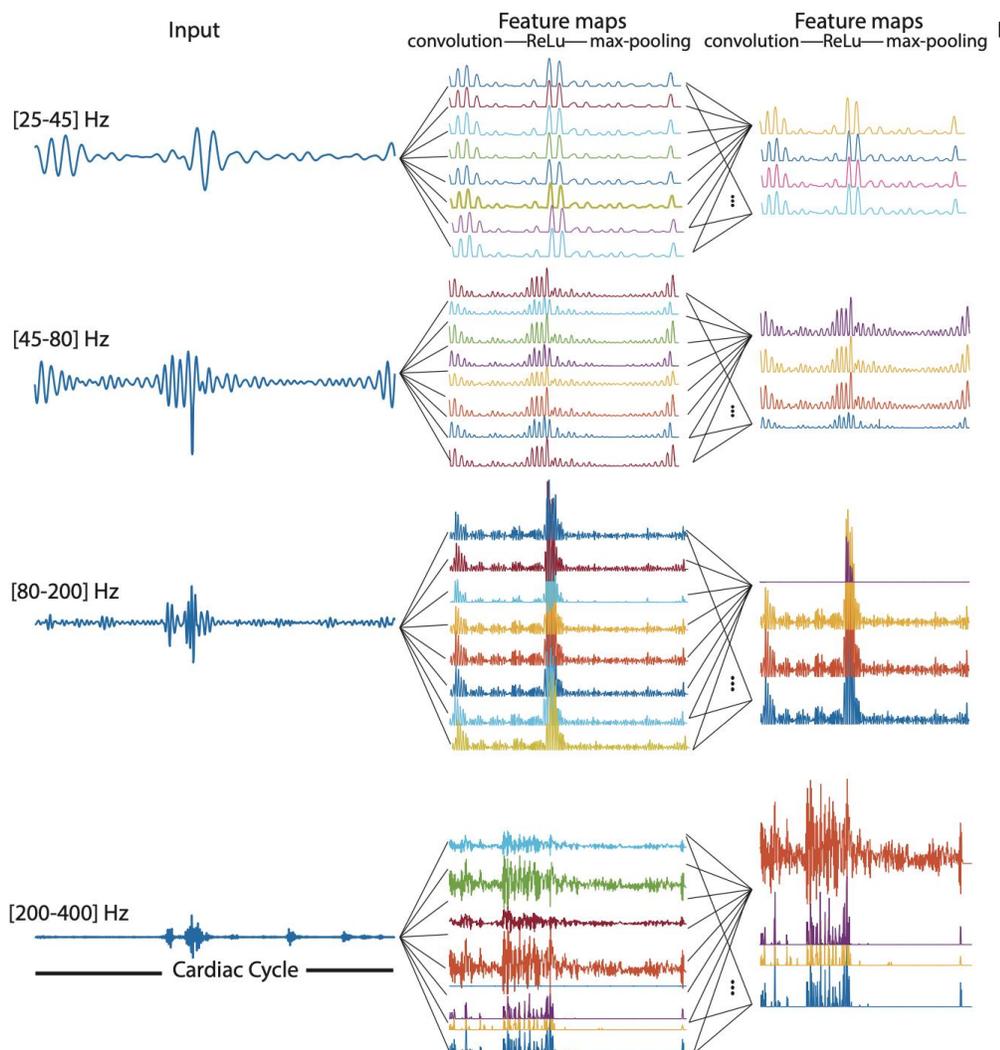
Extracción de características

Una red neuronal artificial estándar usa tanto características del dominio del tiempo como del dominio de la frecuencia, en función de la media y desviación estándar, como la relación entre las amplitudes medias y absolutas de las señales correspondientes.

En el caso de la CNN del presente proyecto, las características se desprenden de la descomposición de los registros PCG en 4 bandas de frecuencia como se muestra en la *Figura 22*.

Figura 22

Representación de los Registros PCG en Bandas de Frecuencia



Nota. Tomado de (Potes, 2016)

- 1ra banda: 25 – 45 Hz
- 2da banda: 45 – 80 Hz
- 3ra banda: 80 – 200 Hz
- 4ta banda: 200 – 400 Hz

Estas bandas se segmentaron en los diferentes ciclos cardiacos con sus correspondientes “sonidos” y “silencios”, S1, S2, sístole y diástole, estos ciclos se contemplaron con una duración de 2.5 segundos, determinados en el algoritmo de segmentación propuesto en (Springer, 2016). En el caso que alguno de los ciclos tuviera una menor duración se completaría con ceros.

El código de las funciones principales para la descomposición de las bandas de frecuencia como características de entrada al CNN se muestran en la *Figura 23*.

Figura 23

Código de Matlab para la Extracción de Características

```
function res = feed_forward_cnn(s,parms)
    nfreqbands = size(s,2);
    flat_out = [];

    % Series de tiempo de 4 bandas de frecuencia
    for fb=1:nfreqbands
        prms.H1 = squeeze(parms.H1(fb,:,:));
        prms.H2 = squeeze(parms.H2(fb,:,:,:));
        prms.b1 = parms.b1(fb,:);
        prms.b2 = parms.b2(fb,:);

        % Parámetros de agrupación máxima
        prms.maxpooling = parms.maxpooling;
        out = feed_forward_filters(s(:,fb),prms);
        flat_out = [flat_out; flatten(out)];
    end
    res = flat_out.*parms.W1 + parms.bias1;
    res(res<=0) = 0;
    res = res*parms.W2 + parms.bias2;
    res = sigmoid(res);
end

% Función de activación sigmoide
function y = sigmoid(x)
    y = 1./(1+exp(-x));
end

function res = flatten(x)
    res = nan(numel(x),1);
    [~,j] = size(x);
    res(1:j:end) = x(:,1);
    res(2:j:end) = x(:,2);
    res(3:j:end) = x(:,3);
    res(4:j:end) = x(:,4);
end
```

Clasificador basado en CNN

En la *Figura 24* se muestra la arquitectura de la red neuronal para la clasificación de los ruidos cardíacos, en la que las series de tiempo corresponden a las cuatro bandas de frecuencias en las que se descompuso la señal de PCG para determinar sus características. Cada una de las CNN está conformada por tres capas, la capa de entrada más dos capas de convolución.

La capa de entrada se relaciona a un ciclo cardíaco de una específica banda de frecuencias, mientras que una capa de convolución infiere una transformación lineal y una operación de agrupación máxima, la misma que evita un sobre entrenaamiento de la red.

La primera capa convolucional consta de ocho filtros, de longitud cinco con una función de activación ReLu y una agrupación máxima de dos, la segunda capa de convolución tiene cuatro filtros de longitud cinco con su correspondiente función de activación y también con una agrupación máxima de dos, entonces se tiene 4 CNN a la salida.

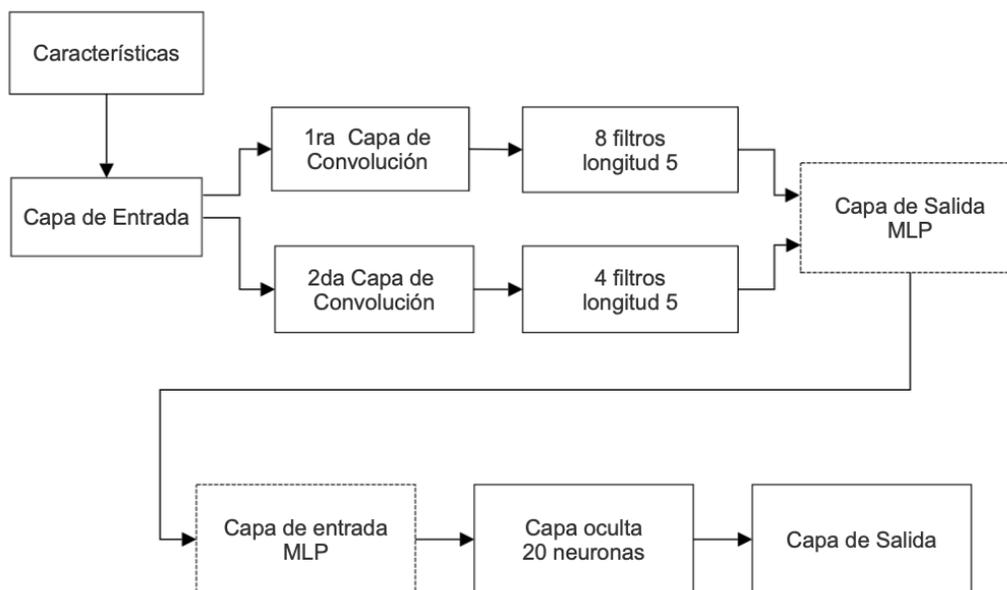
Las 4 CNN resultantes se “aplanan” y se convierten en la capa de entrada de una red de perceptrón multicapa (MLP), seguidas por una capa oculta con 20 neuronas y una capa de salida, para esta nueva red MLP la capa oculta utiliza la función de activación rectificadora (ReLU) mientras que para la capa de salida la función de activación es un sigmoide.

ReLU, es una función lineal por partes que conducirá la entrada directamente a la siguiente etapa si es positiva; de lo contrario, dispondrá cero, mientras que la función de activación sigmoidea, es una función en la que la entrada a la función se transforma

en un valor entre 0.0 y 1.0. Las entradas mayores que 1.0 se transforman al valor 1.0, y las entradas menores que 0.0 se ajustan a 0.0. (Brownlee, 2019)

Figura 24

Arquitectura de CNN para Clasificación de Ruidos Cardíacos



Las correspondientes líneas de código se muestran en la *Figura 25*, siguiendo el flujo de la arquitectura de CNN para la clasificación de ruidos cardíacos, y las funciones principales en cada una de las capas.

Entrenamiento del clasificador

Para el entrenamiento del clasificador se generaron conjuntos de prueba de la base de datos proporcionada por Physionet tomando los registros del subconjunto “f” que cuenta con 114 grabaciones de PCG, mientras que para la validación de la red neuronal convolucional se tomaron los registros de la carpeta de validación proporcionada en la misma base de datos para el propósito.

Una vez realizado el entrenamiento se obtienen los coeficientes y probabilidad almacenados en `parms.m`, el cual debe ser cargado para la ejecución del algoritmo de detección de valvulopatías.

Figura 25

Código de Matlab del Clasificador de Ruidos Cardíacos

```

% Salidas de CNN
function out2 = feed_forward_filters(s,parms)
[nfilters, filter_sz] = size(parms.H1);
out1 = nan(max(length(s)-max(0,filter_sz-1),0)/2,nfilters);
for nf=1:nfilters
    tmp = conv(s,parms.H1(nf,:),'valid') + parms.b1(nf);
    tmp(tmp<=0) = 0; %relu
    tmp = reshape(tmp,parms.maxpooling,length(tmp)/parms.maxpooling);
    tmp = max(tmp)';
    out1(:,nf) = tmp;
end

%Determinación de filtros
[nfilters1,nfilters2,filter_sz] = size(parms.H2);
L = max(size(out1,1)-max(0,filter_sz-1),0);
out2 = nan(L/2,nfilters1);
for k=1:nfilters1
    h = squeeze(parms.H2(k,:,:));
    tmp = 0;
    for nf2=1:nfilters2
        tmp = conv(out1(:,nf2),h(nf2,:),'valid') + tmp;
    end

    % Función de activación ReLu
    tmp = tmp + parms.b2(k);
    tmp(tmp<=0) = 0;

    %Agrupación máxima
    tmp = reshape(tmp,parms.maxpooling,length(tmp)/parms.maxpooling);
    tmp = max(tmp)';
    out2(:,k) = tmp;
end

```

Visualización de señal procesada

Para la visualización de la señal procesada y el resultado obtenido del clasificador se ha desarrollado una interfaz gráfica que permita la carga del archivo a procesar, la ejecución del proceso de la detección de valvulopatías y la presentación del resultado del diagnóstico con dicha señal.

Diseño de la interfaz gráfica

En la *Figura 26* se muestra la vista de diseño del sistema de detección de valvulopatías, compuesta por el logotipo de la Universidad de las Fuerzas Armadas - ESPE, centrada en la parte superior como imagen fija, debajo el título de la interfaz, y un componente de visualización gráfica, en la parte inferior de la ventana se encuentran 3 botones de acción: abrir, ejecutar y guardar.

Figura 26

Diseño de la interfaz

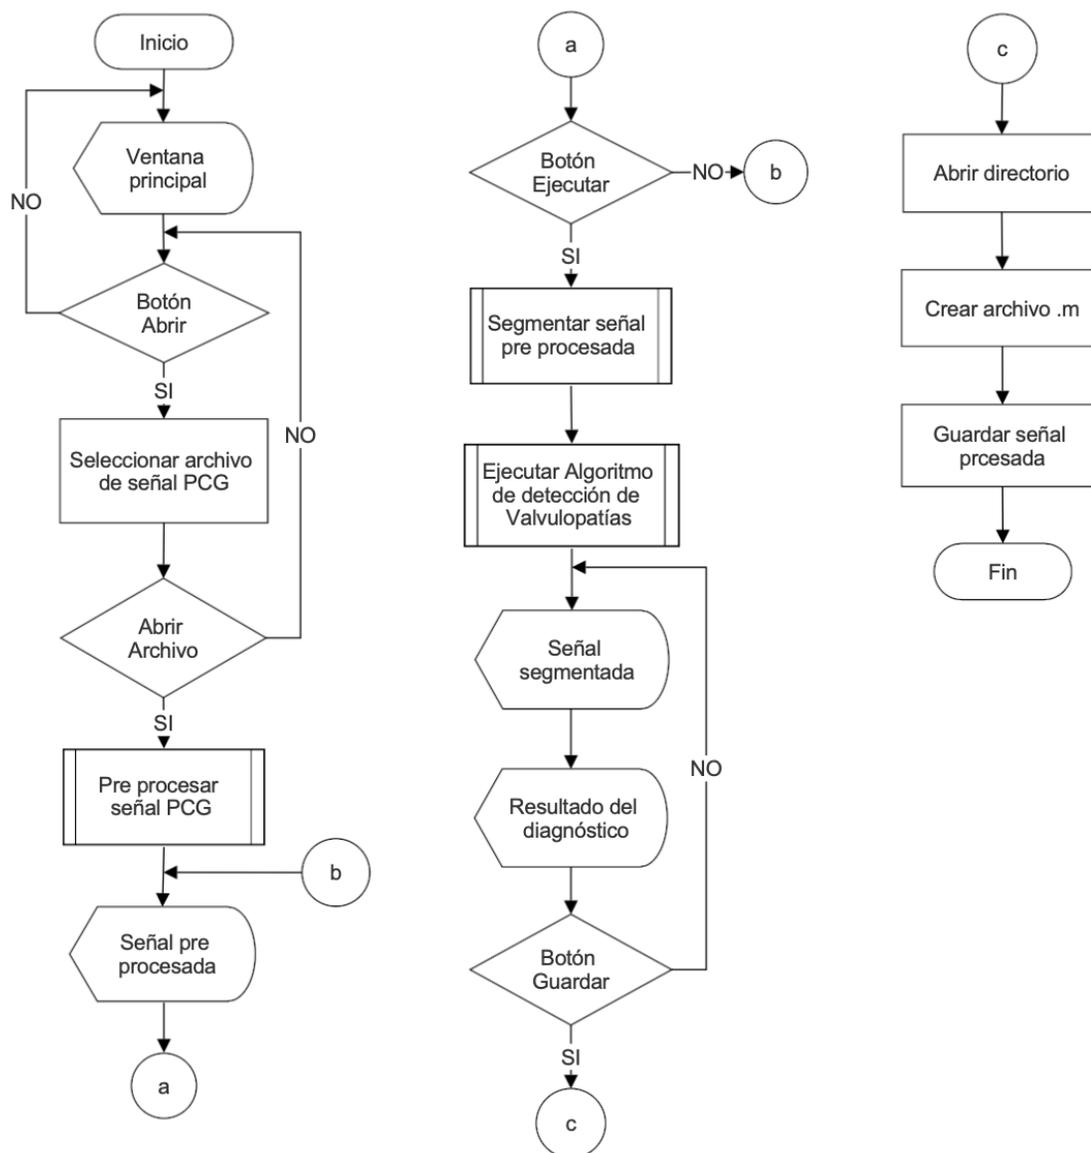


En la *Figura 27* se muestra el diagrama de flujo del funcionamiento de la interfaz que permite ejecutar el sistema de detección de valvulopatías.

Diagrama de flujo de la interfaz

Figura 27

Diagrama de Flujo de la Interfaz



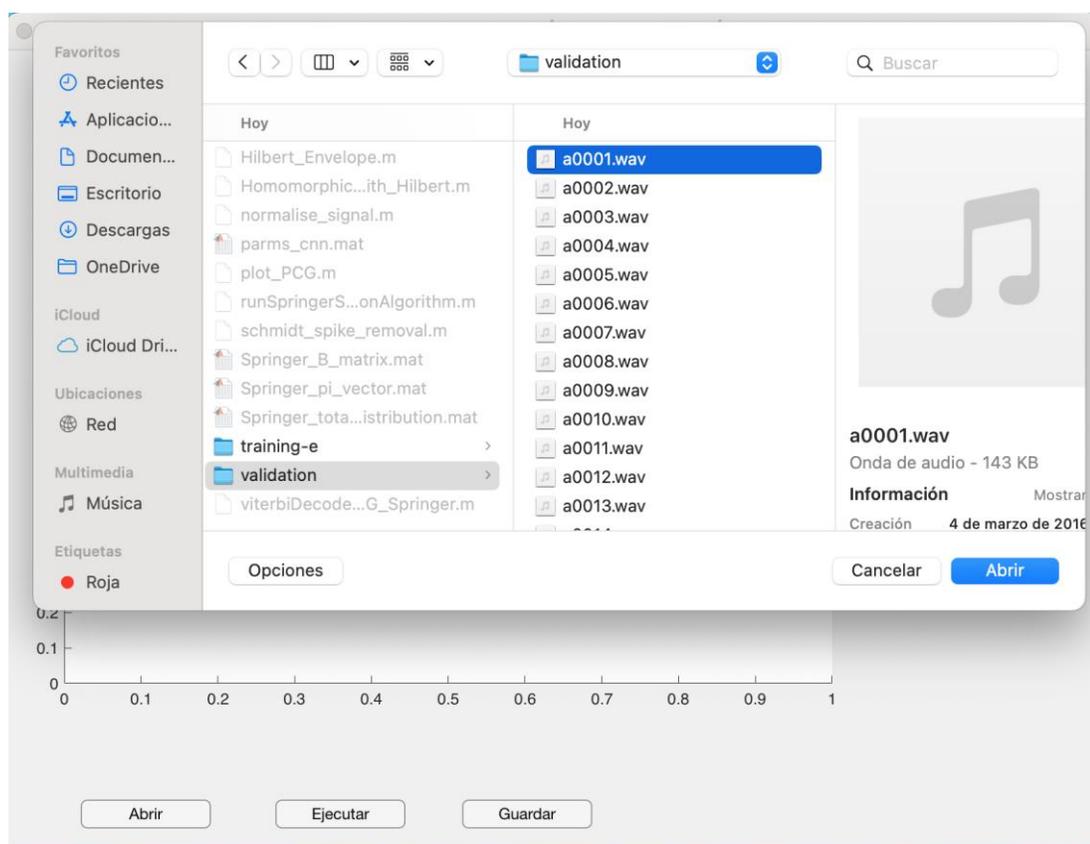
Para el diseño de la interfaz se utilizó el APP Designer, entorno gráfico que permite crear aplicaciones en Matlab con una gran variedad de elementos interactivos, en el presente trabajo se utilizaron principalmente los elementos tipo "Button" y el área de visualización tipo "Axes".

Funcionamiento de la interfaz

Al ejecutar el programa aparece la ventana principal como en la *Figura 26*, la misma que contiene 3 botones, el primero “Abrir” permite abrir el explorador de archivos y ubicar la grabación de PCG en cualquier directorio del sistema operativo, como se muestra en la *Figura 28*. Para que el archivo pueda procesarse debe cumplir con dos condiciones, la primera es que debe estar muestreado a 2000Hz y la segunda es que debe estar en formato .wav, una vez seleccionado el archivo se debe aceptar abrir el mismo.

Figura 28

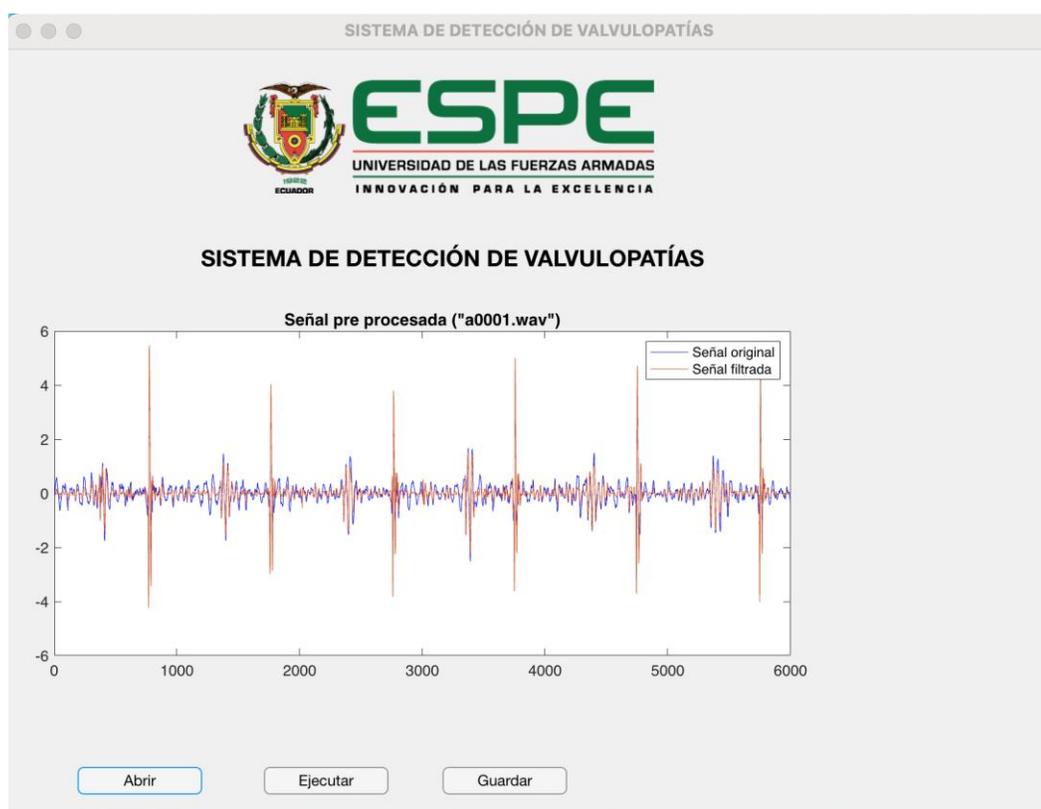
Explorador de Archivos



Si se cancela la apertura del archivo, volverá a la pantalla principal, si se selecciona y abre el archivo, se ejecutará la etapa de pre procesamiento de la señal en el que se normalizará la señal a 1000Hz, se filtrará, se eliminarán los picos de amplitudes, se eliminará el ruido, y se mostrarán las señales tanto original como filtrada en pantalla, de manera superpuesta, de tal modo que se pueda apreciar los cambios al ser pre procesada la señal, como se muestra en la *Figura 29*.

Figura 29

Visualización de Señal Pre Procesada



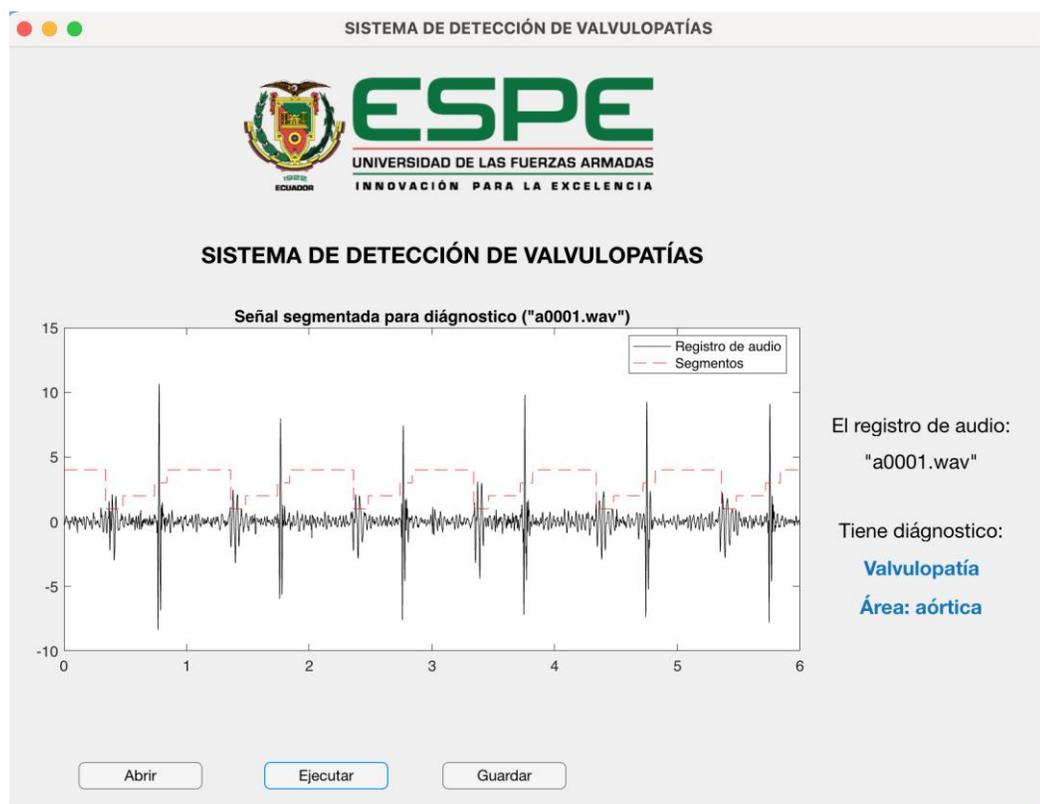
Siguiendo el flujo del diagrama, se debe decidir entre presionar o no el botón “ejecutar”, si este no se presiona la pantalla principal se mantendrá con el gráfico del último registro abierto, si se presiona el botón “ejecutar” entonces se ejecutará la etapa

de segmentación de la señal, en la que se determinarán los segmentos S1, sístole, S2, diástole, y también la etapa de descomposición de la señal en bandas de frecuencia.

Con la señal lista se ejecuta el proceso de clasificación basado en CNN, entonces en la componente de visualización gráfica se borra la señal original, y se grafica los componentes de la segmentación de manera superpuesta, y se muestra el resultado del diagnóstico a la derecha del gráfico, como se ve en la *Figura 30*.

Figura 30

Visualización de los segmentos de la señal y el diagnóstico

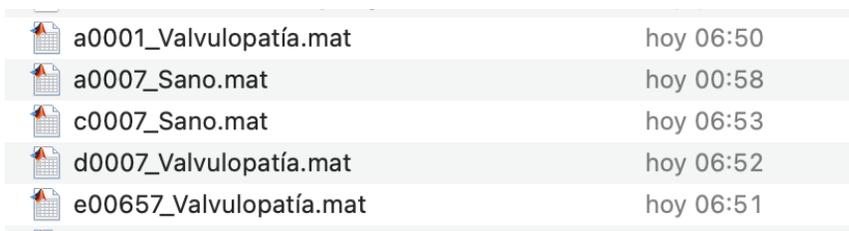


La imagen filtrada puede ser almacenada de manera local en la carpeta del proyecto para su posterior visualización, al presionar en el botón "Guardar" se

almacenará un archivo .m con el nombre del registro y el diagnóstico, como se muestra en la *Figura 31*.

Figura 31

Almacenamiento de la señal filtrada en directorio local

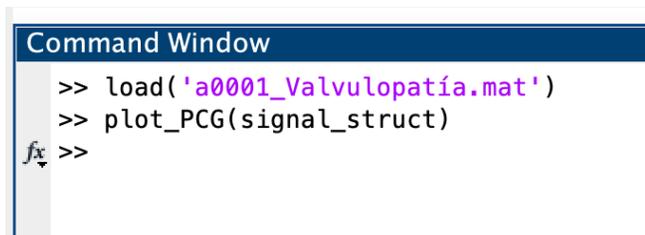


a0001_Valvulopatía.mat	hoy 06:50
a0007_Sano.mat	hoy 00:58
c0007_Sano.mat	hoy 06:53
d0007_Valvulopatía.mat	hoy 06:52
e00657_Valvulopatía.mat	hoy 06:51

Para abrir el archivo en una instancia fuera del algoritmo, se requiere cargar el archivo y ejecutar la función `plot_PCG` (`signal_struct`) en la ventana de comandos de Matlab, como se muestra en *Figura 32*, de esta manera se puede visualizar la señal filtrada del registro deseado.

Figura 32

Almacenamiento de la señal filtrada en directorio local

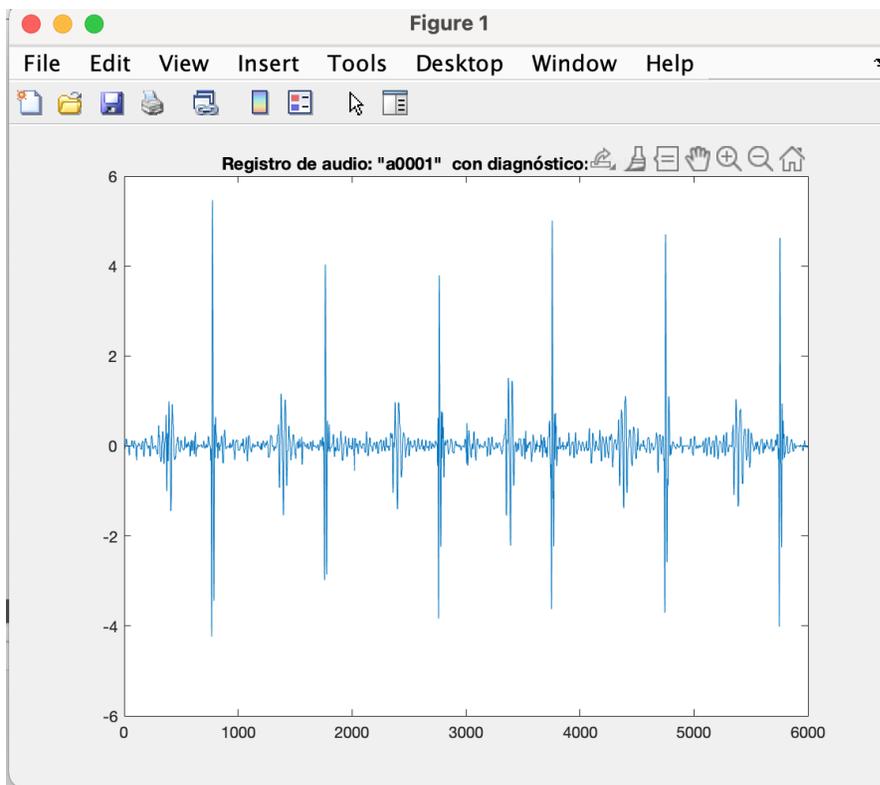


```
Command Window
>> load('a0001_Valvulopatía.mat')
>> plot_PCG(signal_struct)
fx >>
```

Una vez que se ejecuta la función se despliega una nueva ventana que muestra la señal filtrada que se almacenó desde la interfaz, en la parte superior indica el nombre del registro y el diagnóstico, como se muestra en la *Figura 33*.

Figura 33

Visualización de la señal filtrada almacenada desde la interfaz



La ventana de visualización de las señales almacenadas con el diagnóstico se mantiene activa y el gráfico de la señal se actualiza cada vez que se cargue una nueva señal y se ejecute la función `plot_PCG (signal_struct)`, su ejecución es independiente del programa principal, por lo que se pueden ejecutar de manera simultánea.

Para cerrar tanto la ventana principal, como la ventana de visualización de señales con diagnóstico se debe utilizar los botones propios del sistema operativo, los registros y cambios se mantendrán almacenados de manera local en la carpeta del proyecto.

Capítulo IV

Pruebas y análisis de resultados

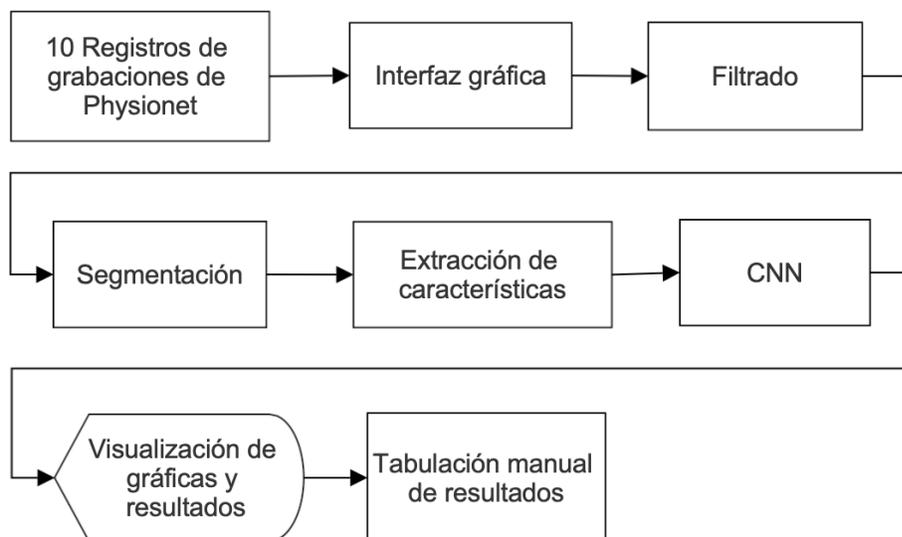
Para el propósito de validar el clasificador se realizaron 2 escenarios de pruebas, el primero con 10 registros usando la interfaz diseñada, y el segundo mediante un script que automatiza la ejecución de todo el proceso de clasificación almacenando los resultados en una matriz.

Primer escenario de pruebas

En el primer escenario de pruebas se utiliza la interfaz gráfica para elegir de manera manual y aleatoria 10 registros a evaluar y compararlos con los valores de referencia proporcionados en la base de datos de Physionet como se muestra en la *Figura 34*.

Figura 34

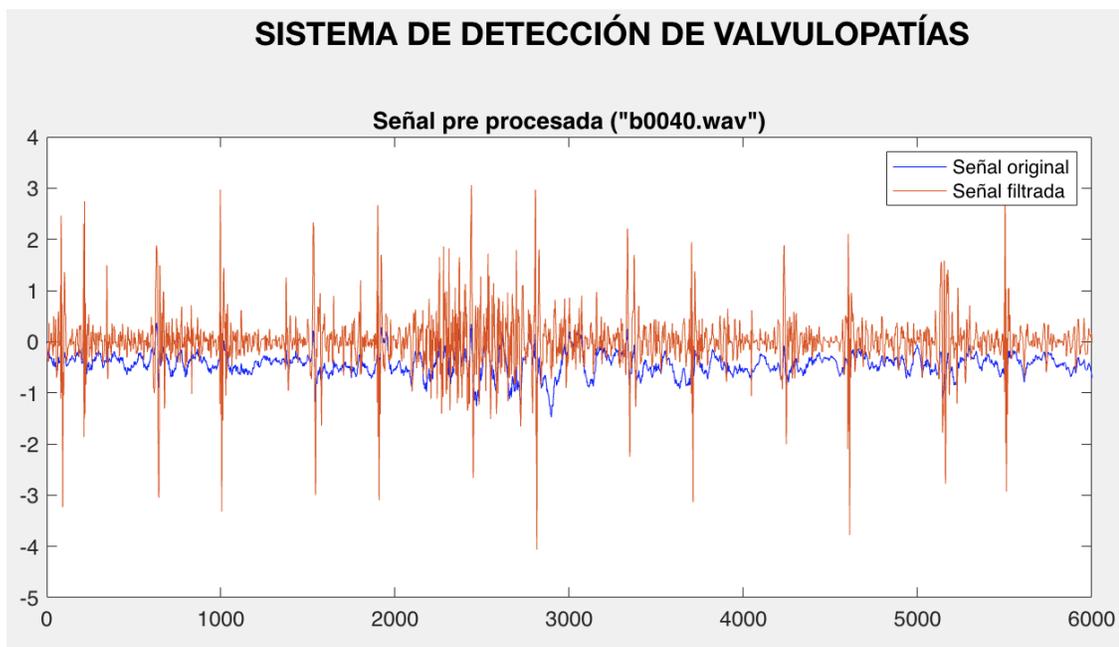
Primer Escenario de Pruebas



Para la verificación de los resultados proporcionados por el algoritmo a través de la interfaz, se eligen 3 de los 10 registros comparados, en la *Figura 35* se muestra la señal filtrada del registro b0040.wav con la respectiva señal de origen, mientras que en la *Figura 36* se muestra la segmentación de la señal y el diagnóstico.

Figura 35

Señal filtrada del registro b0040.wav

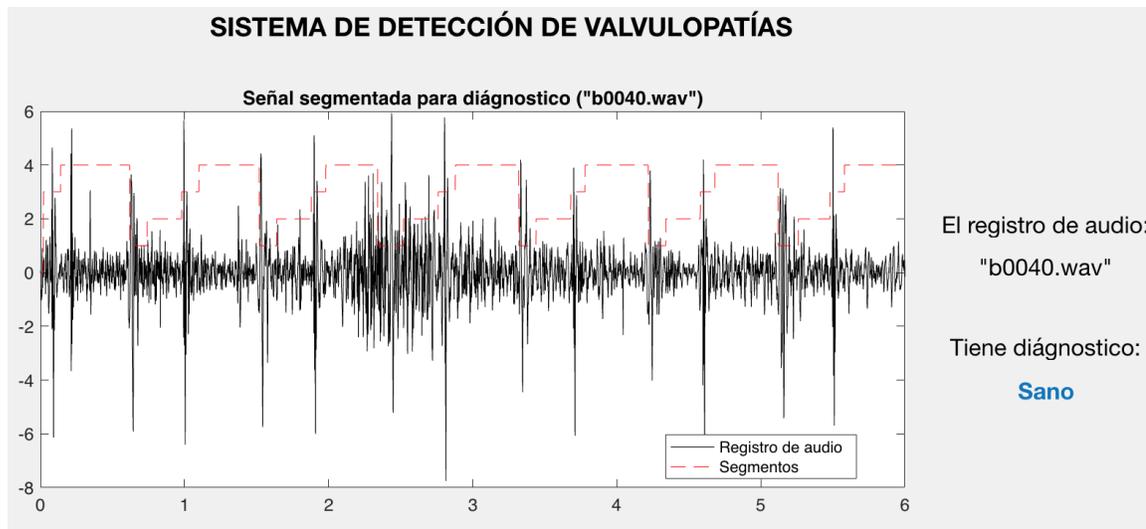


En la *Tabla 5* se puede observar que el diagnóstico presentado por el algoritmo no corresponde con la referencia proporcionada por Physionet, de tal manera que se considera una predicción errónea.

Conforme la gráfica se puede deducir que el algoritmo no puede determinar el resultado adecuado debido a gran cantidad de picos en zonas de "silencio" que presenta el registro, y que se arrastra desde el proceso de filtrado, aunque aun así se pueden establecer de manera clara cada uno de los segmentos, como se muestra en la *Figura 36*

Figura 36

Señal segmentada del registro b0040.wav



En la *Figura 37* y *Figura 38* se muestran las señales filtradas y segmentadas del registro c0031.wav respectivamente.

Figura 37

Señal filtrada del registro c0031.wav

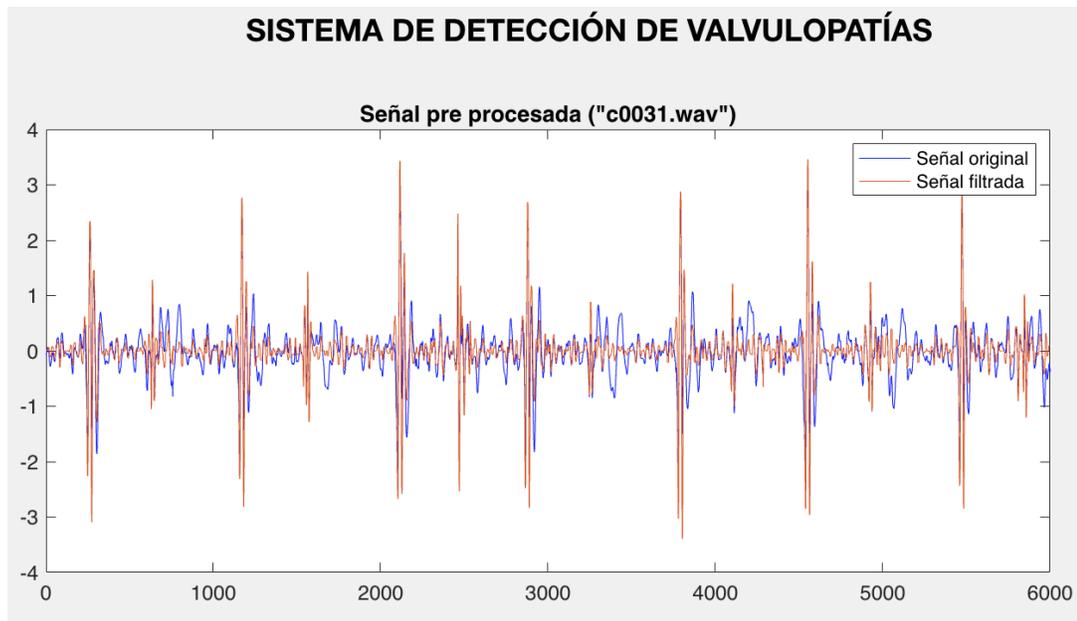
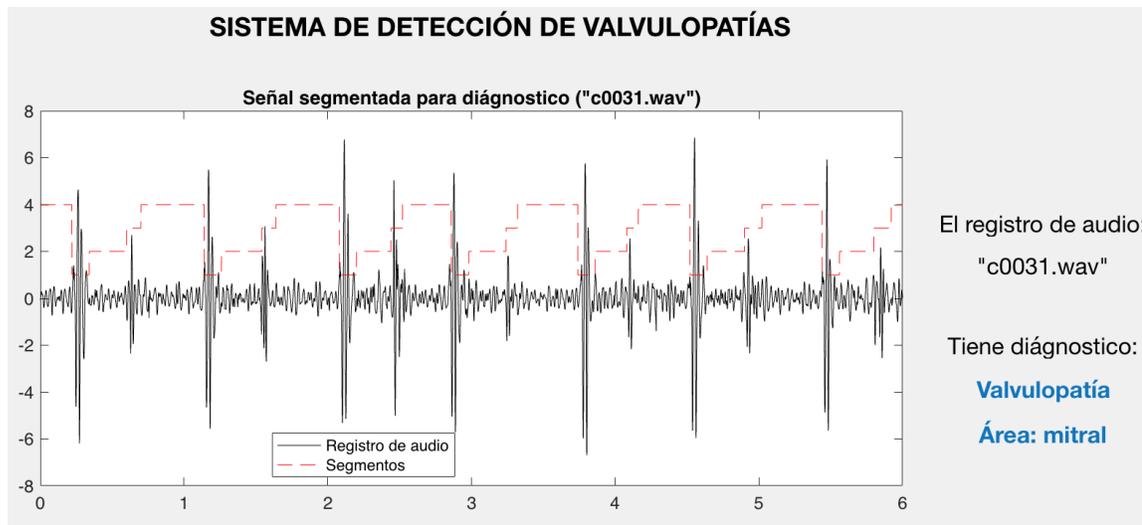


Figura 38

Señal segmentada del registro c0031.wav



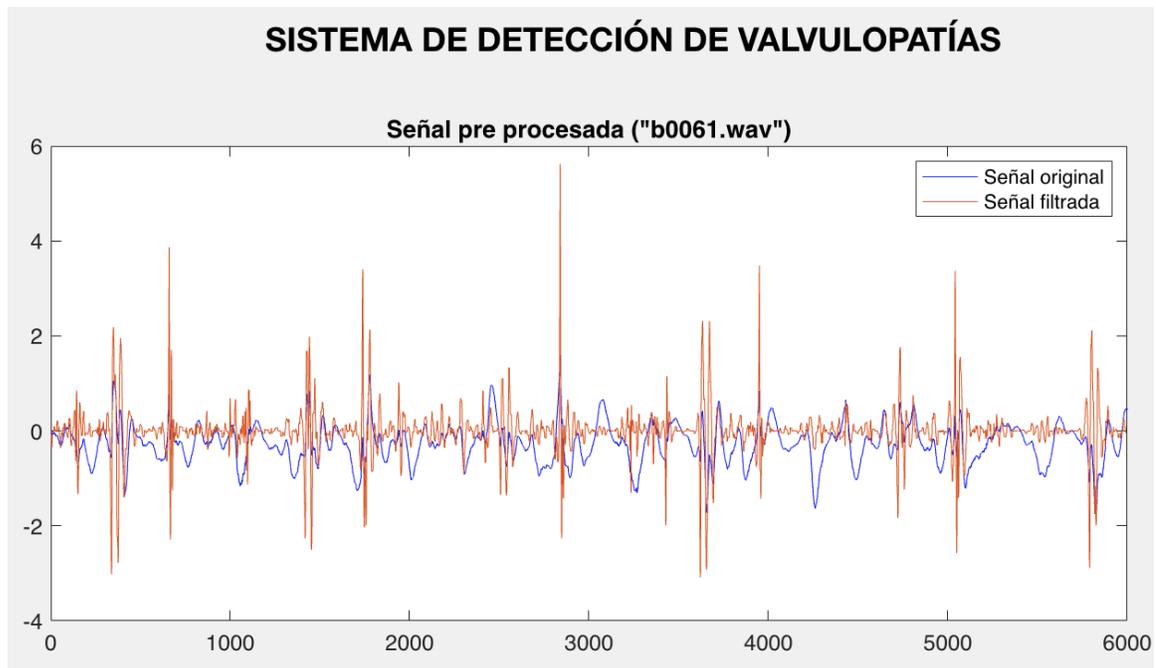
Se puede observar la adecuada segmentación de la señal, así como el diagnóstico. Al comparar con la referencia de Physionet, el diagnóstico coincide con el presentado por el algoritmo como se muestra en la *Tabla 5*.

En la Figura 39 se muestra otra señal obtenida de las grabaciones de la base de datos de Physionet, el registro b0061.wav con la respectiva señal filtrada. En la *Figura 40* se muestra la segmentación del mismo registro con el diagnóstico determinado por el clasificador, que coincide con las referencias de la base de datos.

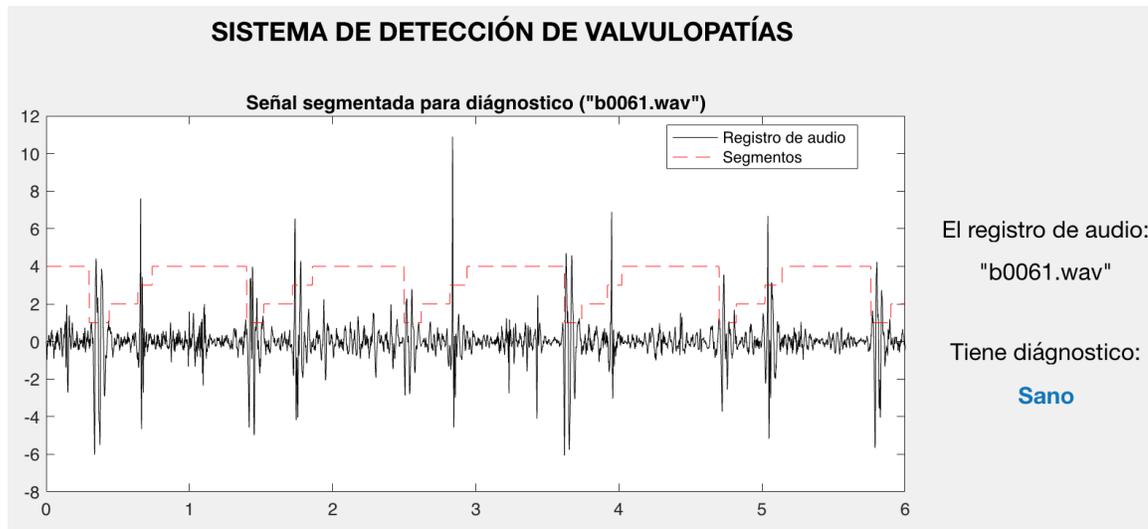
El realizar el proceso manual resulta ineficiente con respecto al tiempo y recursos, al ejecutar de esta manera la validación de cada registro y buscar en las referencias de la base de datos para su posterior tabulación es un proceso poco práctico.

Figura 39

Señal filtrada del registro b0061.wav

**Figura 40**

Señal segmentada del registro b0061.wav



En la *Tabla 5* se muestra los resultados de 10 registros procesados a través de la interfaz, resultando 2 erróneos y 10 acertados, que a priori corresponde a un 80% de asertividad. Para que los resultados se aproximen de manera objetiva a la probabilidad que ofrece el algoritmo se debe considerar una población de muestras mayor.

Tabla 5

Resultados de las Pruebas del Escenario 1

Orden	Registro	Diagnóstico Physionet	Diagnóstico Algoritmo
1	a0007.wav	sano	sano
2	b0040.wav	valvulopatía	* sano
3	e00043.wav	sano	sano
4	e00657.wav	valvulopatía	valvulopatía
5	b0164.wav	valvulopatía	valvulopatía
6	b0024.wav	sano	*valvulopatía
7	a0028.wav	sano	sano
8	c0031.wav	valvulopatía	Valvulopatía
9	e00004.wav	sano	sano
10	b0061.wav	sano	sano

Segundo escenario de pruebas

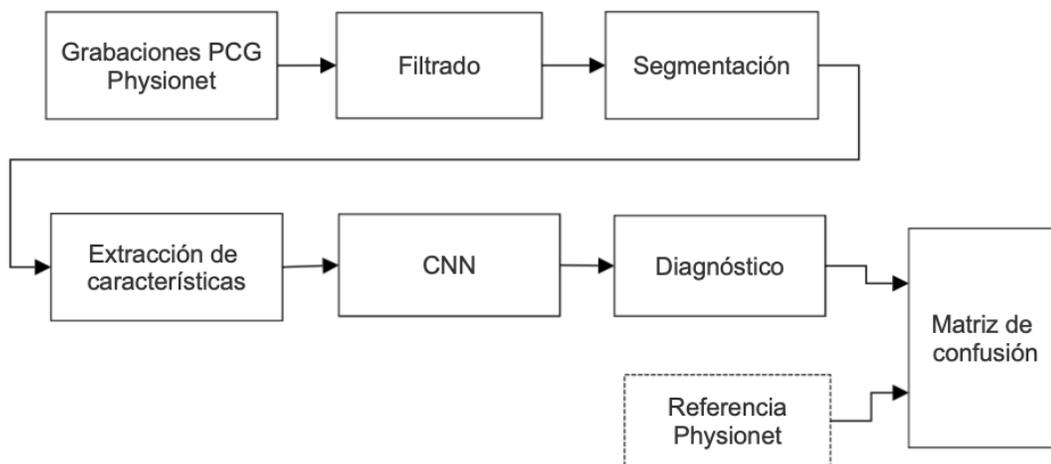
Se plantea un segundo escenario de pruebas en el que se puede analizar un mayor número de registros y comparaciones efectivas con las referencias de Physionet, haciendo uso de herramientas como la matriz de confusión que describe de manera más aproximada el desempeño de un clasificador.

Esta matriz de confusión contiene información sobre las clasificaciones reales y de predicción realizadas por el clasificador y esta información se utiliza para evaluar el rendimiento del mismo.

En la *Figura 41* se muestra el escenario de pruebas, que permite evaluar el rendimiento del clasificador con un mayor número de registros, a través de métricas de desempeño como exactitud, precisión, sensibilidad, y especificidad.

Figura 41

Segundo Escenario de pruebas



En este escenario se realizaron las pruebas con 301 registros de PCG, tomados del subconjunto de validación de Physionet, y a diferencia del primer escenario de

pruebas, en este no se usó la interfaz gráfica, y en su lugar se ejecutaron todas las funciones y procesos desde un script, de tal manera que se reduce el tiempo de procesamiento al no tener que graficar cada uno de los registros y sus señales filtradas y segmentadas.

Para ejecutar este escenario se desarrolló un script que almacena la ubicación y nombres de los registros que van a ser procesados, estos nombres se almacenan en una matriz con el nombre "full_paths". Luego mediante un bucle se llama a cada registro para extraer su señal y se ejecutan las funciones de pre procesamiento y luego el clasificador que ha sido previamente entrenado para generar una matriz de salida llamada "data".

En la *Figura 42* se muestra el script desarrollado para automatizar la comparación de resultados, obtenidos con el clasificador y la referencia de la base de datos, la evaluación de los 301 registros se consigue en tiempo aproximado de 5 min.

Figura 42

Código de Matlab del Script

```
% 3-5 min (aprox.)
% Ubicación de los registros a validar
fds = fileDatastore("validation/*.wav", "ReadFcn", @audioread, "UniformRead", true);
% Almacenamiento de la ubicación + nombre de los registros
full_paths = fds.Files;

for i = 1:length(full_paths)
    full_path = full_paths{i};
    splited_path = split(full_path, '/');
    signal_name = splited_path{end}(1:end-4)

    % En este espacio se ubica el código del programa de cada etapa de
    % procesamiento de la señal

    % Almacenamiento del diagnóstico obtenido
    newPCG(i).PCG_val = signal_name;
    newPCG(i).PCG_res = classifyResult;
end
```

Matriz de confusión

Las matrices de confusión representan recuentos de valores predichos y reales. Se compone de las siguientes salidas.

La salida "TN" significa True Negative, que muestra el número de ejemplos negativos clasificados con precisión. La salida, "TP" significa Verdadero Positivo, que indica el número de ejemplos positivos clasificados con precisión.

El término "FP" muestra un valor falso positivo, es decir, el número de ejemplos negativos reales clasificados como positivos; "FN" significa un valor falso negativo que es el número de ejemplos positivos reales clasificados como negativos.

Las métricas que se pueden obtener a partir de las salidas de la matriz de confusión son útiles para el presente trabajo son: especificidad y sensibilidad.

La especificidad corresponde porcentaje total de registros clasificados de manera correcta.

$$\text{Especificidad} = \frac{TN}{TN + FN}$$

La sensibilidad representa a la cantidad de registros identificados correctamente como positivos, del total de positivos verdaderos.

$$\text{Sensibilidad} = \frac{TP}{TP + FN}$$

En la *Tabla 6* se muestra la simbología empleada para colocar los resultados en la matriz que permita aplicar el análisis estadístico respectivo.

Tabla 6*Matriz de Confusión Simple*

		Predicted	
		Negative	Positive
Actual	Negative	TN	FP
	Positive	FN	TP

Nota. Tomado de (Kulkarni, 2020)

Resultados de las pruebas con el segundo escenario

En la *Figura 43* se muestran las salidas obtenidas aplicando la matriz de confusión, de las cuales se interpreta que se evaluaron 301 registros de PCG de los cuales 126 son pacientes sanos y 175 pacientes con valvulopatías.

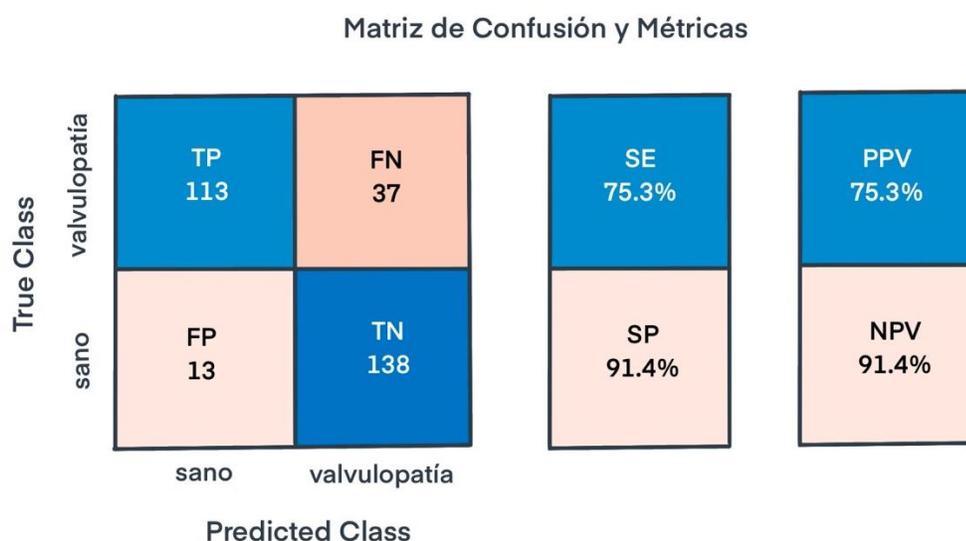
El clasificador diagnóstico como sanos a 113 registros de manera exitosa, mientras que 13 no fueron diagnosticados correctamente como sanos. Como pacientes con valvulopatías el clasificador diagnosticó a 138 pacientes de manera correcta mientras que 37 fueron diagnosticados de manera errónea.

En términos porcentuales se alcanzó una sensibilidad del 75.3% y una especificidad del 91.4%, al realizar la comparación con los métodos investigados de la *Tabla 3* determinamos que el valor de sensibilidad ha sido el más bajo de los 5 métodos, mientras que en cuanto a especificidad se ha obtenido un resultado muy bueno, siendo superado solo por el trabajo de (Zabihi, 2016).

El promedio de la sensibilidad y especificidad es de 83,35% lo cual determina que la clasificación de sonidos cardíacos propuesta en el presente trabajo se encuentra en la media de los resultados obtenidos por otras investigaciones, que permite ser un punto de partida importante para futuros desarrollos.

Figura 43

Matriz de Confusión y Métricas de Desempeño



El tiempo promedio de ejecución del segundo escenario de pruebas mediante el uso del script creado para evaluar los 301 registros y generar las salidas de la matriz de confusión y las métricas de sensibilidad y especificidad fue de 5 minutos, mientras que en el primer escenario el tiempo para realizar la comparación y tabulación de un solo registro es en promedio 28 segundos, para completar la validación de los 301 registros se requeriría de aproximadamente 140 minutos.

Capítulo V

Conclusiones y recomendaciones

Conclusiones

Una vez realizado el pre procesamiento de la señal utilizando los filtros de Butterword y segmentando con HSSM se concluye que este preprocesamiento permite identificar en forma correcta los sonidos cardíacos, que constituyen el requerimiento indispensable como entrada para el clasificador.

Para la determinación de los parámetros óptimos de entrenamiento se consideró una adecuada segmentación que permita identificar los sonidos y las etapas del ciclo cardíaco, así como la descomposición en bandas de frecuencia de la señal cardíaca, siendo estos los insumos adecuados para el proceso de entrenamiento y un adecuado diagnóstico del clasificador.

La implementación del algoritmo utilizando redes neuronales convolucionales nos ha permitido obtener un porcentaje de acierto de un 89.7% en diagnóstico de pacientes sanos y 78.9% en diagnóstico de pacientes con valvulopatías, lo cual demuestra una capacidad diagnóstica adecuada del algoritmo.

Una vez realizadas las pruebas con un universo de 301 registros tomados de la base de datos de Physionet, con el algoritmo implementado en el presente proyecto se ha obtenido una especificidad del 91.4% y una sensibilidad del 75.3% que comparado con el trabajo más relevante en esta área presentado en (Zabihi, 2016) que obtuvo 88.76% de especificidad y 94.23% de sensibilidad, se concluye que el algoritmo implementado con CNN responde adecuadamente con el parámetro de especificidad.

La interfaz gráfica desarrollada para la ejecución del algoritmo permite un manejo fácil y amigable con cualquier tipo de usuario, facilitando de esta forma la operación de este software por personal médico.

Considerando que los resultados obtenidos en cuanto a especificidad son relevantes con respecto a otros trabajos de investigación en esta área se concluye que los objetivos planteados para el desarrollo del presente proyecto se han cumplido satisfactoriamente.

Recomendaciones

Considerando la naturaleza de las señales cardíacas que son de baja intensidad y que pueden ser fácilmente contaminadas por ruidos externos, se recomienda una etapa de pre procesamiento adecuada que permita reducir al máximo posible los ruidos que pudieran afectar a la señal, sin que en el proceso se pierda información importante de la actividad cardíaca.

Para una operación adecuada del algoritmo desarrollado se recomienda verificar que las grabaciones de sonidos cardíacos ha ser analizados sean archivos de audio en formato .wav y que tengan una tasa de muestreo de 2000Hz, para garantizar de esta forma una óptima ejecución del algoritmo que permita determinar si el registro puede ser procesado.

Para la validación adecuada del algoritmo se recomiendan registros cardíacos de fuentes confiables como las proporcionadas por Physionet, que contienen las referencias de diagnóstico evaluadas por médicos especialistas que han determinado si las señales corresponden a pacientes sanos o con afecciones cardíacas.

Trabajos futuros

Una vez determinado que la sensibilidad es baja con respecto al promedio de otros trabajos se propone como trabajo futuro la utilización de técnicas más complejas de segmentación que complementen la acción diagnóstica del algoritmo desarrollado en el presente proyecto.

Bibliografía

- Ali, A. (2020, 10). *The cardiac Cycle*. Retrieved from UTMB Health Pediatrics:
https://www.utmb.edu/Pedi_Ed/CoreV2/cardiology/Cardiology3.html
- Anatomía del Corazón*. (SF). Retrieved from Texas Heart Institute :
<https://www.texasheart.org/heart-health/heart-information-center/topics/anatomia-del-corazon/>
- BABU, A. (2020). Automatic Recognition of Fundamental Heart Sound Segments From PCG Corrupted With Lung Sounds and Speech. *School of Electrical Sciences, Indian Institute of Technology Bhubaneswar*.
- Boutana, D. (2011). SEGMENTATION AND TIME-FREQUENCY ANALYSIS OF PATHOLOGICAL HEART SOUND SIGNALS USING THE EMD METHOD. *IET Signal Process*.
- Brownlee, J. (2019, junio). *A Gentle Introduction to the Rectified Linear Unit (ReLU)* . Retrieved from Machine Learning Mastery:
<https://machinelearningmastery.com/rectified-linear-activation-function-for-deep-learning-neural-networks/>
- Chung, Y. (2007). Classification of Continuous Heart Sound Signals Using the Ergodic Hidden Markov Model. *Pattern Recognition and Image Analysis*.
- Classification of Heart Sound Recordings*. (marzo de 2016). Recuperado el noviembre de 2020, de <https://physionet.org>: <https://physionet.org/content/challenge-2016/1.0.0/>

El Corazón. (SF). Retrieved from ICARITO: <http://www.icarito.cl/2010/07/60-2825-9-el-corazon.shtml/>

El sistema de conducción. (SF). Retrieved from Texas Heart Institute:
<https://www.texasheart.org/heart-health/heart-information-center/topics/el-sistema-de-conduccion/>

Hamidi, M. (2018). Classification of heart sound signal using curve fitting and fractal dimension. *Biomedical Signal Processing and Control*.

Heart Foundation. (SF). *Heart Valve Disease*. Retrieved from
<https://www.heartfoundation.org.nz>: <https://www.heartfoundation.org.nz/your-heart/heart-conditions/heart-valve-disease>

Homsy, M. (2016). Automatic Heart Sound Recording Classification using a Nested Set of Ensemble Algorithms . *Computing in Cardiology Challenge*.

INEC. (2014). *Estadísticas Vitales Registro Estadístico de Nacidos vivos y Defunciones 2016*. Retrieved from <http://www.ecuadorencifras.gob.ec>:
http://www.ecuadorencifras.gob.ec/documentos/web-inec/Poblacion_y_Demografia/Nacimientos_Defunciones/2016/Presentacion_Nacimientos_y_Defunciones_2016.pdf

Kaniusas, E. (2017). Acoustical signals of biomechanical systems. *ResearchGate*.

Klabunde, R. (2015). *Cardiovascular Physiology Concepts*. Retrieved from
<https://www.cvphysiology.com>:
<https://www.cvphysiology.com/Heart%20Disease/HD010>

- Kulkarni, A. (2020). *Confusion Matrix*. Retrieved from ScienceDirect:
<https://www.sciencedirect.com/topics/engineering/confusion-matrix>
- Kumar, D. (2007). Third heart sound detection using wavelet transform-simplicity filter. *Engineering in Medicine and Biology Society*.
- Li, J. (2019). Classification of Heart Sounds Based on the Wavelet Fractal and Twin Support Vector Machine. *Entropy*.
- Liang, H. (1997). Heart sound segmentation algorithm based on heart sound envelogram. *Computers in Cardiology 1997*.
- Moukadem, A. (2013). A robust heart sounds segmentation module based on S-transform. *Elseiver*.
- Naseri, H. (2013). Detection and boundary identification of phonocardiogram sounds using an expert frequency-energy based metric. *Ann Biomed Enineering*.
- PAHO. (2016). *ECUADOR: PERFIL DE ENFERMEDADES CARDIOVASCULARES*. Retrieved from <https://www.paho.org/>:
<https://www.paho.org/hq/dmdocuments/2014/ECUADOR-PERFIL-ECV-2014.pdf>
- Palani, T. (2020). Automated heart sound classification system from unsegmented phonocardiogram (PCG) using deep neural network. *Physical and Engineering Sciences in Medicine*.
- Potes, C. (2016). Ensemble of Feature-based and Deep learning-based Classifiers for Detection of Abnormal Heart Sounds. *Philips Research*.

- Reynolds, A. H. (2019). *Convolutional Neural Networks (CNNs)*. Retrieved from <https://anhreynolds.com/>: <https://anhreynolds.com/blogs/cnn.html>
- Rubin, J. (2016). Classifying Heart Sound Recordings using Deep Convolutional Neural Networks and Mel-Frequency Cepstral Coefficients. *he PhysioNet Computing in Cardiology Challenge*.
- Sarmiento, J. (2019). Applications of neural networks and deep learning to biomedical engineering. *Revista UIS Ingenierías*.
- Schmidt, S. E. (2008). Segmentation of Heart Sound Recordings from an Electronic Stethoscope by a Duration Dependent Hidden-Markov Model. *2008 Computers in Cardiology*.
- Springer, D. B. (2016). *Logistic Regression-HSMM-based Heart Sound Segmentation*. IEEE.
- Tamariz, M. (2016). *Auscultación Cardíaca*. Retrieved from *Pediatría Integral*: <https://www.pediatriaintegral.es/publicacion-2016-10/auscultacion-cardiaca/>
- Tang, H. (2012). Segmentation of heart sounds based on dynamic clustering. *Biomedical Signal Processing and Control*.
- Tschannen, M. (2016). Heart Sound Classification Using Deep Structured Features. *Computing in Cardiology Challenge*.
- Vernekar, s. (2016). A Novel Approach for Classification of Normal/Abnormal Phonocardiogram Recordings using Temporal Signal Analysis and Machine Learning. *The PhysioNet Computing in Cardiology Challenge*.

- Vinay, K. (2020). Heart Sounds – Clinically Explained. *EPOMEDICINE*.
- Wang, X. (2020). Temporal-Framing Adaptive Network for Heart Sound Segmentation Without Prior Knowledge of State Duration. *IEEE Transactions on Biomedical Engineering*.
- WHO. (2017). *Enfermedades cardiovasculares*. Retrieved from <http://www.who.int>:
<http://www.who.int/es/news-room/fact-sheets/detail/cardiovascular->
- William, S. (2020, 2). *What Are The Four Heart Sounds?* Retrieved from Medicinet:
https://www.medicinenet.com/what_are_the_four_heart_sounds/article.htm
- Yaseen. (2018). Classification of Heart Sound Signal Using Multiple Features. *Applied Science*.
- Yuenyong, S. (2011). A framework for automatic heart sound analysis without segmentation. *US National Library of Medicine National Institutes of Health*.
- Zabihi, M. (2016). Heart Sound Anomaly and Quality Detection using Ensemble of Neural Networks without Segmentation. *The PhysioNet Computing in Cardiology Challenge*.
- Zhang, W. (2017). Heart sound classification based on scaled spectrogram and tensor decomposition. *Expert Systems with Applications*.

