

MARIO FERNANDO JOJOA ACOSTA



**COMPARACIÓN DE TRES SISTEMAS DE CLASIFICACIÓN DE SEÑALES
FONOCARDIOGRÁFICAS BASADOS EN DISTINTAS TÉCNICAS DE
EXTRACCIÓN DE CARACTERÍSTICAS**

**Universidad del Cauca
Facultad de Ingeniería Electrónica y Telecomunicaciones
Maestría en Electrónica y Telecomunicaciones**

**Popayán
2018**

MARIO FERNANDO JOJOA ACOSTA

**COMPARACIÓN DE TRES SISTEMAS DE CLASIFICACIÓN DE SEÑALES
FONOCARDIOGRÁFICAS BASADOS EN DISTINTAS TÉCNICAS DE
EXTRACCIÓN DE CARACTERÍSTICAS**

**Tesis presentada a la Facultad de Ingeniería
Electrónica y Telecomunicaciones de la
Universidad del Cauca para la obtención del
Título de**

**Magíster en
Electrónica y Telecomunicaciones.**

**Director:
MSc. Harold Armando Romo Romero**

**Popayán
2018**

Hoja de Aprobación:

Abstract

The automatic computer classification of biomedical signals allows the implementation of new systems that help to solve the problems of the health service in the most remote and poorest regions of the world. In this sense, information technologies must provide models with low computational cost and high reliability, that can be implemented in portable devices of mass diffusion compatible with geographical spaces, where coverage limitations are found and the existing health service is deficient. In this way, remote sensing and telediagnosis become fundamental issues that contribute to improving the quality of life of people affected by the social conditions of their countries.

Based on the above, its necessary an investigation to compare the performance of different classification models with the task of identifying pathologies in the adult human heart having as input the sound generated during its operation. It is clear that if there is any anomaly in the behavior, this will be reflected in the sounds produced during cardiac activity in different stages of the cycle, hence they are called systolic or diastolic noises as appropriate.

This document presents a comparison of the performance in terms of success rate, error rate, sensitivity and specificity of different models of automatic classification that base their operation on three proposals for extracting characteristics: Decimal envelope, HOG descriptor, and Wavelets for the classification of phonocardiographic signals. The document is divided into 6 chapters where the first 3 explore the theoretical concepts that support the objectives of the work. In Chapter 4 is the methodology that begins describing the form of collection of the normal and pathological phonocardiographic signals used in the exposed research, continuing with the procedures used for the extraction of characteristics and the

validation of the vectorial support machine classifiers and neuronal network. Later in chapter 5 the results obtained in the classification tests of each proposed models for different classes normal and pathological are documented, and finally in chapter 6 the conclusions are expressed and future research works are proposed.

This work contributes to the development of classification systems applied to the detection of human pathologies, because it is a very broad topic and important field that commits universities and research organizations to formulate projects that lead to the advancement of telemedicine as a reality in the different points of our region.

Keywords: Support vector machine, Neural Networks, Classifiers, Feature extraction, HOG, Decimation

Resumen

La clasificación automática por computador de señales biomédicas permite la implementación de nuevos sistemas que ayudan a solucionar los problemas del servicio de la salud en las regiones más apartadas y más pobres del mundo. En ese sentido las tecnologías de la información deben proveer de modelos de bajo costo computacional y alta fiabilidad que puedan ser implementados en dispositivos portables de difusión masiva compatibles con los espacios geográficos donde se encuentran limitaciones de cobertura y el servicio existente de salud es deficiente. De esta manera la teledetección y el tele diagnóstico se convierten en temas fundamentales que contribuyen en la mejora de la calidad de vida de las personas afectadas por las condiciones sociales propias de países subdesarrollados.

Con base en lo anterior se decide realizar una investigación en la cual se busca comparar el desempeño de distintos modelos de clasificación con la tarea de identificar patologías en el corazón humano adulto teniendo como insumo el sonido que genera durante su funcionamiento. Es claro que si existe alguna anomalía en el comportamiento, esta se verá reflejada en los sonidos producidos durante la actividad cardiaca en distintas etapas del ciclo, de ahí que se los denomina ruidos sistólicos o diastólicos según corresponda.

En este documento se presenta una comparación del desempeño en términos de tasa de acierto, tasa de error, sensibilidad y especificidad de distintos modelos de clasificación automática que basan su funcionamiento en tres propuestas de extracción de características: Envolvente decimada, descriptor HOG y Wavelets para la clasificación de señales fonocardiográficas. El documento se divide en 5

capítulos donde los 2 primeros exploran los conceptos teóricos que sustentan los objetivos del trabajo. En el capítulo 3 se encuentra la metodología que inicia describiendo la forma de recopilación de las señales fonocardiográficas normales y patológicas utilizadas en la investigación expuesta, continuando con los procedimientos utilizados para la extracción de características y la validación de los clasificadores tipo máquina de soporte vectorial y red neuronal. Posteriormente en el capítulo 4 se consigan los resultados obtenidos en las pruebas de clasificación de cada uno de los modelos propuestos para distintas clases de señales tanto normales como patológicas y finalmente en el capítulo 5 se expresan las conclusiones obtenidas y se proponen trabajos futuros de investigación relacionados al tema.

Se espera contribuir en el desarrollo de sistemas de clasificación aplicados a la detección de patologías humanas, un campo muy amplio pero de mucho auge que compromete a las universidades y a los entes de investigación a formular proyectos que conlleven al avance de la telemedicina como una realidad en los distintos puntos de nuestra región.

Palabras Clave: Máquina de soporte vectorial, Redes Neuronales, Clasificadores, Extracción de características, HOG, Decimación.

Contenido

| | |
|---|-----|
| Lista de Tablas | xi |
| Lista de Figuras | xv |
| Lista de abreviaturas | xix |
| Lista de símbolos | xxi |
| Capítulo 1 | 23 |
| Funcionamiento del corazón | 23 |
| 1.1 El Corazón Humano | 23 |
| 1.2 Anatomía general y funcionamiento del corazón | 24 |
| 1.3 Sonidos característicos del corazón | 25 |
| 1.4 Diagnóstico de enfermedades cardiacas | 26 |
| 1.4.1 Enfermedades relacionadas al funcionamiento del corazón | 26 |
| 1.4.2 El fonendoscopio y la auscultación | 26 |
| Capítulo 2 | 29 |
| Métodos de extracción de características y clasificación | 29 |
| 2.1 La transformada de Hilbert | 29 |
| 2.2 El descriptor HOG | 30 |
| 2.3 La transformada discreta de Wavelet | 31 |
| 2.4 Las redes neuronales | 33 |
| 2.5 La máquina de soporte vectorial | 34 |
| 2.6 Validación cruzada | 35 |
| 2.7 Parámetros de medición del rendimiento de un clasificador | 35 |
| 2.8 Octave | 37 |
| 2.9 Python | 38 |
| Capítulo 3 | 39 |
| Metodología | 39 |
| 3.1 Señales fonocardiográficas | 39 |

| | |
|---|-----|
| 3.2 Extracción de características - Envolverte y clasificación..... | 45 |
| 3.3 Extracción de características – Imágenes y descriptor HOG | 46 |
| 3.4 Extracción de características – Wavelets..... | 48 |
| Capitulo 4 | 51 |
| Resultados | 51 |
| Capitulo 5 | 97 |
| Conclusiones..... | 97 |
| Bibliografía | 99 |
| Apendices..... | 101 |

Lista de Tablas

| | | |
|-----------|--|----|
| Tabla 1.1 | Ruidos del ciclo cardiaco [4]..... | 25 |
| Tabla 2.1 | Función en octave para el cálculo de la envolvente..... | 30 |
| Tabla 2.2 | Función para el cálculo del descriptor HOG..... | 31 |
| Tabla 2.3 | Función para el cálculo del descriptor HOG..... | 32 |
| Tabla 2.4 | Matriz de Confusión..... | 36 |
| Tabla 3.1 | Ruidos de las señales de entrada y sus SNR..... | 39 |
| Tabla 3.2 | Caraterísticas de las señales de entrada..... | 40 |
| Tabla 4.1 | Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características envolvente decimada. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Normal..... | 86 |
| Tabla 4.2 | Parámetros de rendimiento de un clasificador tipo ANN con modelo de extracción de características envolvente decimada. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Normal..... | 87 |
| Tabla 4.3 | Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características envolvente decimada. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Sistólico..... | 87 |
| Tabla 4.4 | Parámetros de rendimiento de un clasificador tipo ANN con modelo de extracción de características envolvente decimada. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Sistólico..... | 88 |
| Tabla 4.5 | Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características envolvente decimada. | |

| | | |
|------------|---|----|
| | Datos obtenidos bajo la metodología K-Folds para la clase Sonido Diastólico..... | 88 |
| Tabla 4.6 | Parámetros de rendimiento de un clasificador tipo ANN con modelo de extracción de características envolvente decimada. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Diastólico..... | 89 |
| Tabla 4.7 | Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características descriptor HOG. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Normal..... | 89 |
| Tabla 4.8 | Parámetros de rendimiento de un clasificador tipo ANN con modelo de extracción de características descriptor HOG. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Normal..... | 90 |
| Tabla 4.9 | Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características descriptor HOG. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Sistólico..... | 90 |
| Tabla 4.10 | Parámetros de rendimiento de un clasificador tipo ANN con modelo de extracción de características descriptor HOG. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Sistólico..... | 91 |
| Tabla 4.11 | Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características descriptor HOG. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Diastólico..... | 91 |
| Tabla 4.12 | Parámetros de rendimiento de un clasificador tipo ANN con modelo de extracción de características descriptor HOG. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Diastólico..... | 92 |
| Tabla 4.13 | Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características Wavelets. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Normal..... | 92 |

| | | |
|------------|--|----|
| Tabla 4.14 | Parámetros de rendimiento de un clasificador tipo ANN con modelo de extracción de características Wavelets. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Normal..... | 93 |
| Tabla 4.15 | Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características Wavelets. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Sistólico..... | 93 |
| Tabla 4.16 | Parámetros de rendimiento de un clasificador tipo ANN con modelo de extracción de características Wavelets. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Sistólico..... | 94 |
| Tabla 4.17 | Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características Wavelets. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Diastólico..... | 94 |
| Tabla 4.18 | Parámetros de rendimiento de un clasificador tipo ANN con modelo de extracción de características Wavelets. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Diastólico..... | 95 |
| Tabla 4.19 | Resumen del desempeño de los clasificadores | 95 |

Lista de Figuras

| | | |
|--------------|---|----|
| Figura 1. 1 | El corazón humano [2] | 24 |
| Figura 1. 2 | Fonendoscopio Clásico | 27 |
| Figura 2. 1 | Etapas en el cálculo del descriptor HOG | 31 |
| Figura 3. 1 | Sonido Normal sin ruido adicionado..... | 40 |
| Figura 3. 2 | Sonido Normal con ruido blanco gaussiano adicionado SNR 10 dB..... | 41 |
| Figura 3. 3 | Sonido Normal con ruido blanco gaussiano adicionado SNR 100 dB..... | 42 |
| Figura 3. 4 | Sonido Sistólico sin ruido adicionado..... | 42 |
| Figura 3. 5 | Sonido Sistólico con ruido blanco gaussiano adicionado SNR 10 dB..... | 42 |
| Figura 3. 6 | Sonido Sistólico con ruido blanco gaussiano adicionado SNR 100 dB..... | 43 |
| Figura 3. 7 | Sonido Diastólico sin ruido adicionado..... | 43 |
| Figura 3. 8 | Sonido Diastólico con ruido blanco gaussiano adicionado SNR 10 dB..... | 44 |
| Figura 3. 9 | Sonido Diastólico con ruido blanco gaussiano adicionado SNR 100 dB..... | 44 |
| Figura 3. 10 | Etapas de clasificación y validación | 45 |
| Figura 3. 11 | Etapas de mapeo y extracción de características de las señales como imágenes..... | 47 |
| Figura 3. 12 | Etapas de mapeo y extracción de características de las señales con Wavelets..... | 48 |
| Figura 4. 1 | Porcentaje de error vs valor de la constante de decimación | 51 |
| Figura 4. 2 | Envolvente del Sonido Normal con ruido | 52 |
| Figura 4. 3 | Envolvente decimada en 50 del Sonido Normal con ruido..... | 53 |

| | | |
|--------------|---|----|
| Figura 4. 4 | Envolvente del Sonido Sistólico con ruido | 53 |
| Figura 4. 5 | Envolvente decimada en 50 del Sonido Sistólico con ruido | 54 |
| Figura 4. 6 | Envolvente del Sonido Diastólico con ruido | 54 |
| Figura 4. 7 | Envolvente decimada en 50 del Sonido Diastólico con ruido..... | 55 |
| Figura 4. 8 | Normal sin ruido adicionado..... | 56 |
| Figura 4. 9 | Normal con ruido adicionado SNR 20 dB..... | 56 |
| Figura 4. 10 | Normal con ruido adicionado SNR 10 dB..... | 57 |
| Figura 4. 11 | Sistólico sin ruido adicionado..... | 57 |
| Figura 4. 12 | Sistólico con ruido adicionado SNR 20 dB..... | 58 |
| Figura 4. 13 | Sistólico con ruido adicionado SNR 10 dB..... | 58 |
| Figura 4. 14 | Diastólico sin ruido adicionado..... | 59 |
| Figura 4. 15 | Diastólico con ruido adicionado SNR 20 dB..... | 59 |
| Figura 4. 16 | Diastólico con ruido adicionado SNR 10 dB..... | 60 |
| Figura 4. 17 | Estructura del vector de características conformado a través del cálculo de momentos estadísticos de la descomposición Wavelet..... | 60 |
| Figura 4. 18 | Sonido normal y su espectro..... | 61 |
| Figura 4. 19 | Reconstrucción sonido normal con coeficientes de aproximación .. | 62 |
| Figura 4. 20 | Reconstrucción sonido normal con coeficientes de detalle 1 | 62 |
| Figura 4. 21 | Reconstrucción sonido normal con coeficientes de detalle 2..... | 63 |
| Figura 4. 22 | Reconstrucción sonido normal con coeficientes de detalle 3..... | 63 |
| Figura 4. 23 | Reconstrucción sonido normal con coeficientes de detalle 4..... | 64 |
| Figura 4. 24 | Reconstrucción sonido normal con coeficientes de detalle 5..... | 64 |
| Figura 4. 25 | Reconstrucción sonido normal con coeficientes de detalle 6..... | 65 |
| Figura 4. 26 | Reconstrucción sonido normal con coeficientes de detalle 7..... | 65 |
| Figura 4. 27 | Reconstrucción sonido normal con coeficientes de detalle 8..... | 66 |
| Figura 4. 28 | Reconstrucción sonido normal con coeficientes de detalle 9..... | 66 |
| Figura 4. 29 | Reconstrucción sonido normal con coeficientes de detalle 10..... | 67 |
| Figura 4. 30 | Reconstrucción sonido normal con coeficientes de detalle 11..... | 67 |
| Figura 4. 31 | Reconstrucción sonido normal con coeficientes de detalle 12..... | 68 |
| Figura 4. 32 | Reconstrucción sonido normal con coeficientes de detalle 13..... | 68 |
| Figura 4. 33 | Sonido normal reconstruido | 69 |
| Figura 4. 34 | Sonido sistólico y su espectro | 70 |
| Figura 4. 35 | Reconstrucción sonido sistólico con coeficientes de aproximación..... | 70 |

| | | |
|--------------|--|----|
| Figura 4. 36 | Reconstrucción sonido sistólico con coeficientes de detalle 1 | 71 |
| Figura 4. 37 | Reconstrucción sonido sistólico con coeficientes de detalle 2 | 71 |
| Figura 4. 38 | Reconstrucción sonido sistólico con coeficientes de detalle 3 | 72 |
| Figura 4. 39 | Reconstrucción sonido sistólico con coeficientes de detalle 4 | 72 |
| Figura 4. 40 | Reconstrucción sonido sistólico con coeficientes de detalle 5 | 73 |
| Figura 4. 41 | Reconstrucción sonido sistólico con coeficientes de detalle 6 | 73 |
| Figura 4. 42 | Reconstrucción sonido sistólico con coeficientes de detalle 7 | 74 |
| Figura 4. 43 | Reconstrucción sonido sistólico con coeficientes de detalle 8 | 74 |
| Figura 4. 44 | Reconstrucción sonido sistólico con coeficientes de detalle 9 | 75 |
| Figura 4. 45 | Reconstrucción sonido sistólico con coeficientes de detalle 10 | 75 |
| Figura 4. 46 | Reconstrucción sonido sistólico con coeficientes de detalle 11 | 76 |
| Figura 4. 47 | Reconstrucción sonido sistólico con coeficientes de detalle 12 | 76 |
| Figura 4. 48 | Reconstrucción sonido sistólico con coeficientes de detalle 13 | 77 |
| Figura 4. 49 | Sonido sistólico reconstruido..... | 77 |
| Figura 4. 50 | Sonido diastólico y su espectro..... | 78 |
| Figura 4. 51 | Reconstrucción sonido diastólico con coeficientes de aproximación..... | 78 |
| Figura 4. 52 | Reconstrucción sonido diastólico con coeficientes de detalle 1 | 79 |
| Figura 4. 53 | Reconstrucción sonido diastólico con coeficientes de detalle 2 | 79 |
| Figura 4. 54 | Reconstrucción sonido diastólico con coeficientes de detalle 3 | 80 |
| Figura 4. 55 | Reconstrucción sonido diastólico con coeficientes de detalle 4 | 80 |
| Figura 4. 56 | Reconstrucción sonido diastólico con coeficientes de detalle 5 | 81 |
| Figura 4. 57 | Reconstrucción sonido diastólico con coeficientes de detalle 6 | 81 |
| Figura 4. 58 | Reconstrucción sonido diastólico con coeficientes de detalle 7 | 82 |
| Figura 4. 59 | Reconstrucción sonido diastólico con coeficientes de detalle 8 | 82 |
| Figura 4. 60 | Reconstrucción sonido diastólico con coeficientes de detalle 9 | 83 |
| Figura 4. 61 | Reconstrucción sonido diastólico con coeficientes de detalle 10 | 83 |
| Figura 4. 62 | Reconstrucción sonido diastólico con coeficientes de detalle 11 | 84 |
| Figura 4. 63 | Reconstrucción sonido diastólico con coeficientes de detalle 12 | 84 |
| Figura 4. 64 | Reconstrucción sonido diastólico con coeficientes de detalle 13 | 85 |
| Figura 4. 65 | Reconstrucción del sonido diastólico | 85 |

Lista de abreviaturas

| | |
|-----|--|
| SVM | Support Vector Machine – Maquina de Soporte Vectorial |
| ANN | Artificial Neural Network – Red Neuronal Artificial |
| TP | True Positive – Verdadero Positivo |
| TN | True Negative – Falso Negativo |
| FP | False Positive – Falso Positivo |
| FN | False Negative – Falso Negativo |
| CCR | Correct Classification Rate – Tasa de acierto o eficiencia |
| ERR | Error |
| HT | Hilbert Transform – Transformada de Hilbert |

Lista de símbolos

| | |
|--------|----------------------|
| { } | Llaves de conjunto |
| () | Parentesis |
| T | Traspuesta |
| $f()$ | Función |
| $< >$ | Mayor que, Menor que |
| \in | Pertenencia |
| \sim | Complemento |


Capítulo 1

Funcionamiento del corazón

1.1 El Corazón Humano

Es el órgano más importante del sistema circulatorio y se encarga de bombear la sangre a través de un sistema cerrado de canales llamados vasos sanguíneos. Se compone principalmente por tejido muscular (miocardio) y en menor proporción por tejido conectivo y fibroso (Válvulas). Su estructura se divide en cuatro cavidades, dos en la parte superior llamadas aurículas y dos en la parte inferior denominadas ventrículos. De cada lado, tanto izquierdo como derecho, las aurículas se comunican con el ventrículo correspondiente a través de los orificios auriculoventriculares, que pueden estar cerrados por la válvula mitral y tricúspide. Es muy importante resaltar que las cavidades izquierdas no se comunican con las cavidades derechas [1]. A continuación se muestra una imagen de un corazón humano facilitada por el Hearsh Institute of Texas.

Figura 1. 1 El corazón humano [2]



1.2 Anatomía general y funcionamiento del corazón

Este se encuentra entre los pulmones en el centro del pecho, detrás y a la izquierda del esternón. Una membrana de dos capas, llamada pericardio envuelve el corazón como en una bolsa. La capa interna del pericardio está unida al músculo cardíaco y se separa de la capa externa por una capa de líquido que permite que el corazón se mueva al latir mientras permanece unido al cuerpo [2].

Las válvulas que controlan el flujo de sangre por el corazón son cuatro: [2]

- La válvula tricúspide: controla el flujo sanguíneo entre la aurícula derecha y el ventrículo derecho.
- La válvula pulmonar: controla el flujo sanguíneo del ventrículo derecho a las arterias pulmonares, las cuales transportan la sangre a los pulmones para oxigenarla.
- La válvula mitral: permite que la sangre rica en oxígeno proveniente de los pulmones pase de la aurícula izquierda al ventrículo izquierdo.
- La válvula aórtica: permite que la sangre rica en oxígeno pase del ventrículo izquierdo a la aorta, la arteria más grande del cuerpo, la cual transporta la sangre al resto del organismo.

1.3 Sonidos característicos del corazón

Los ruidos cardiacos son la expresión sonora del cierre de las válvulas cardiacas; su funcionamiento siempre es unidireccional, lo cual permite la correcta circulación de la sangre a través del circuito cardiovascular. La auscultación permite la identificación de estos sonidos, que no siempre son del cierre de las válvulas sino que pueden ser por la interrupción del flujo laminar de la sangre al convertirse en turbulento, generando otros ruidos en el momento sistólico o diastólico [3].

Para llevar a cabo esta tarea los profesionales de la salud hacen uso del fonendoscopio, inventado por Laenec, quien usó un cuaderno enrollado para escuchar los sonidos de una paciente con claras patologías cardiacas [3]. Hoy en día se encuentran distintos modelos y de distintas tecnologías que ayudan al profesional de la salud en esta tarea que puede ser complicada; por tal razón, el médico debe entrenar el oído por años con el fin de identificar estos ruidos que son la guía para conocer el estado fisiológico del corazón de la persona que está siendo auscultada. En ese sentido estos ruidos dan información vital del estado funcional del órgano en cuestión. La siguiente tabla muestra los ruidos presentes en ciclo cardiaco:

Tabla 1.1 Ruidos del ciclo cardiaco [4]

| Sonidos | Características | Puntos Críticos |
|-----------|---|--|
| S1 | Compuesto por dos componentes: Mitral y Tricuspídeo. El primer componente, el mitral M1 es ocasionado por el cierre de la válvula Mitral. El segundo componente, resulta del cierre de la válvula tricúspide. | Puede aumentar de intensidad debido a un intervalo P-R corto, contracción ventricular vigorosa; puede disminuir de intensidad en un P-R prolongado, que puede indicar una disfunción ventricular. De igual forma una pérdida de flujo laminar puede causar un ruido diastólico o un ruido sistólico indicando una patología. |

| | | |
|-----------|---|---|
| S2 | Compuestos por dos componentes Aórtico y Pulmonar | Puede aumentar de intensidad como consecuencia de una hipertensión arterial sistémica o una hipertensión arterial pulmonar. |
|-----------|---|---|

1.4 Diagnóstico de enfermedades cardiacas

1.4.1 Enfermedades relacionadas al funcionamiento del corazón

En el órgano principal del sistema circulatorio se pueden presentar infinidad de enfermedades; sin embargo, serán de interés las patologías que puedan alterar los sonidos característicos descritos anteriormente. Es muy importante resaltar que no interesarán las afectaciones que alteren la intensidad de la señal puesto que en el tratamiento matemático, que se explicará en los siguientes capítulos, se describirá la normalización de las señales con el fin de eliminar este efecto. Serán de mucho interés las que estén relacionadas con el ruido diastólico y con el ruido sistólico. A continuación se presentan algunas enfermedades de este tipo:

- La estenosis aórtica es una valvulopatía cardiaca caracterizada por el estrechamiento anormal del orificio de la válvula aórtica del corazón disminuyendo el flujo de sangre hacia el resto del cuerpo. Puede ser congénita aunque de igual forma se presenta por la acumulación de calcio en adultos mayores [5].
- La estenosis mitral es una valvulopatía cardiaca caracterizada por el estrechamiento anormal del orificio de la válvula mitral del corazón. Es común en los países subdesarrollados por causa congénita o por causa reumática [6].

1.4.2 El fonendoscopio y la auscultación

El *estetoscopio*, conocido también como *fonendoscopio*, es un elemento empleado principalmente en medicina humana, medicina veterinaria y enfermería para oír los sonidos internos del cuerpo. Generalmente se usa en la *auscultación* de los latidos cardíacos o los ruidos respiratorios y, en algunas ocasiones, para enfocarse en ruidos intestinales o soplos por flujos anómalos sanguíneos en arterias.

El fonendoscopio clásico está constituido por un tubo de goma que se conecta en un extremo a una campana y a un diafragma y por el otro, se divide en dos tubos, los cuales encajan en dos olivas que se adaptan a los oídos. El primer tubo es el encargado de conducir los sonidos de auscultación captados por la campana y el diafragma, hacia los dos tubos terminales, los cuales a su vez deben producir un cierto tipo de amplificación para finalmente permitir que los sonidos sean escuchados por el usuario.



Figura 1. 2 Fonendoscopio Clásico

Usualmente se cree que la fabricación de un estetoscopio es elemental; sin embargo, uno de buena calidad requiere la aplicación de técnicas especializadas y de precisión. La campana debe estar hecha de un material que permita oír nítidamente los sonidos captados. La longitud de los tubos es importante ya que su actividad dependerá de la frecuencia del sonido. El diámetro del tubo también es importante: sus medidas generalmente son de 25 cm de longitud y 3 mm de diámetro. Las piezas que son introducidas en los oídos deben encajar de la mejor manera posible, ya que de otra manera penetraría aire en el oído del usuario, provocando mucho ruido de fondo. Por último, la membrana del diafragma debe estar fabricada de un material especial que amplifique los sonidos provenientes del cuerpo.

La *auscultación* es un proceso que consiste en escuchar los sonidos provenientes de algún fenómeno; dicho proceso generalmente se lleva a cabo por medio de un estetoscopio. Los profesionales de la salud auscultan rutinariamente los pulmones, el corazón y los intestinos de un paciente para evaluar la frecuencia, intensidad,

duración, número y/o calidad de los sonidos, dependiendo de cuál sea el objetivo de observación. De esta forma se observa que el sonido producido por algún fenómeno permite obtener una idea sobre este, aun si existe alguna separación debida a un medio determinado. Debido a esto se ha encontrado un gran número de métodos aplicables en el campo de la medicina tanto no invasivos como medianamente invasivos [3].

Capítulo 2

Métodos de extracción de características y clasificación

2.1 La transformada de Hilbert

Definida en el dominio del tiempo es la convolución entre el transformador de Hilbert $TH = \frac{1}{\pi t}$ y una función $f(t)$. Una función $f(t)$ y su transformada de Hilbert $H(f(t))$ están relacionadas de manera que juntas forman una señal denominada analítica fuerte. La señal analítica fuerte puede ser escrita con una amplitud y una fase donde la derivada de la fase puede ser identificada como la frecuencia instantánea. Entre las principales aplicaciones de la transformada de Hilbert están el diseño de filtros pasa banda y el cálculo de la señal analítica, y esta a su vez permite calcular la envolvente.

Señal Analítica. Sea una señal real $g(t)$. Se define la señal analítica positiva $g_+(t)$ de la señal $g(t)$, como la función compleja dada por la ecuación (2.2), donde $Hg(t)$ es la transformada de Hilbert de $g(t)$. Como puede verse, la parte real de la señal analítica positiva es la señal dada y la parte imaginaria su transformada de Hilbert.

$$g_+(t) = g(t) + jHg(t) \quad (2.1)$$

Considerando que el espectro de la señal anterior se encuentra centrado en f , esta se puede expresar de esta manera

$$g_+(t) = \tilde{g}(t) * e^{j2\pi ft} \quad (2.2)$$

donde la magnitud de $g_+(t)$ corresponde a la envolvente natural de $g(t)$ [7].

Para el cálculo de la transformada de Hilbert, con el fin de obtener la señal analítica y la envolvente se utiliza el lenguaje de programación de alto nivel OCTAVE. Las características de la función son las siguientes:

Tabla 2.1 Función en octave para el cálculo de la envolvente

| | |
|---|----------------------|
| <i>Nombre: envolvente</i> | |
| Parámetros de entrada | Parámetros de salida |
| Senal | Envol |
| <i>Sintaxis</i> | |
| envol=envolvente(Senal) | |
| <i>Descripción</i> | |
| Con el uso de la función Hilbert incluida en el paquete SIGNAL se calcula la función analítica y su norma. Devuelve la envolvente de la señal de entrada. | |

2.2 El descriptor HOG

Este método fue propuesto por Dalal y Triggers en el año 2005 y apunta a ser una técnica estable para la detección de siluetas dentro de una imagen. Inicialmente se usó para la detección de humanos, que con el uso de un clasificador se pudiera determinar a distintas escalas la existencia de personas en la imagen. Sin embargo en este trabajo se busca aplicar el mismo modelo para la extracción de características de señales fonocardiográficas previamente configuradas como matrices de píxeles. A continuación se describen las etapas para el cálculo del descriptor HOG [8]




Figura 2. 1 Etapas en el cálculo del descriptor HOG

En la actualidad existen librerías que permiten el cálculo de este tipo de descriptor, las cuales son del libre uso. OPENCV ofrece la función dentro de su grupo de rutinas previamente diseñadas para la visión por computadora.

Tabla 2.2 Función para el cálculo del descriptor HOG

| <i>Nombre: descriptorHOG</i> | |
|---|----------------------|
| Parámetros de entrada | Parámetros de salida |
| espacial | HOG |
| winSize | |
| blockSize | |
| blockStride | |
| cellSize | |
| derivAperture | |
| winSigma | |
| <i>Sintaxis</i> | |
| HOG=descriptorHOG(espacial,winSize,blockSize,blockStride,cellSize,winSigma) | |
| <i>Descripción</i> | |
| Se usa librerías de openCV en Python para el cálculo del descriptor HOG. Devuelve el histograma de orientación de los gradientes. | |

2.3 La transformada discreta de Wavelet

Esta Transformada es eficiente para el análisis local de señales no estacionarias y de rápida transitoriedad y, al igual que la Transformada de Fourier con Ventana, mapea la señal en una representación de tiempo-escala. El aspecto temporal de las señales es preservado. La diferencia está en que la Transformada Wavelet

proporciona análisis de multiresolución con ventanas dilatadas. El análisis de las frecuencias de mayor rango se realiza usando ventanas angostas y el análisis de las frecuencias de menor rango se hace utilizando ventanas anchas [9]. Las Wavelets, funciones bases de la Transformada Wavelet, son generadas a partir de una función Wavelet básica, mediante traslaciones y dilataciones. Estas funciones permiten reconstruir la señal original a través de la Transformada Wavelet inversa. La Transformada Wavelet no es solamente local en tiempo, sino también en frecuencia. Dentro de los usos de esta poderosa herramienta podemos nombrar, además del análisis local de señales no estacionarias, el análisis de señales electrocardiográficas, sísmicas, de sonido, de radar, así como también es utilizada para la compresión y procesamiento de imágenes y reconocimiento de patrones.

Puntualmente, la transformada discreta de Wavelets devuelve vectores de coeficientes de aproximación y detalle dependiendo del nivel de descomposición aplicado, donde cada uno contiene información de la señal original en diferentes escalas. La siguiente tabla muestra las características de la función en OCTAVE que permite obtener los vectores mencionados:

Tabla 2.3 Función para el cálculo del descriptor HOG

| | |
|--|-----------------------------|
| <i>Nombre: transformada rápida de wavelet</i> | |
| Parámetros de entrada | Parámetros de salida |
| Datos de entrada f | Vectores de coeficientes C |
| Definición del wavelet w | Estructura de información I |
| Nivel de descomposición J | |
| <i>Sintaxis</i> | |
| [C, I]=fwt(f,w,J) | |
| <i>Descripción</i> | |
| Devuelve el vector C con los coeficientes de detalle y aproximación y la estructura I con la información de la transformación. Esto lo hace para J niveles utilizando la wavelet w especificada. | |

2.4 Las redes neuronales

Las redes neuronales hacen una pequeña parte del gran conjunto de sistemas bioinspirados; en este caso, claramente están basadas en un modelo tomado del cerebro. Esto significa que se intenta plasmar las características esenciales de una neurona real a la hora de diseñar una neurona “artificial”. Sin embargo, la manera en que estas neuronas están organizadas es desconocida casi en su totalidad, con lo que los modelos artificiales presentan una distribución (llamada arquitectura de la red) totalmente diseñada para este fin, sin ninguna pretensión de semejanza biológica. Las principales características de estos sistemas de clasificación se listan a continuación:

Aprendizaje Adaptativo. Capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.

Auto-organización. Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.

Tolerancia a fallos. La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo un gran daño.

Operación en tiempo real. Los cálculos neuronales pueden ser realizados en paralelo; para esto se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.

Fácil inserción dentro de la tecnología existente. Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilitará la integración modular en los sistemas existentes. [10]

2.5 La máquina de soporte vectorial

La SVM es un potente clasificador discriminativo utilizado en reconocimiento de patrones. Formalmente, la SVM es una máquina de decisión que proporciona un hiperplano de separación óptimo para alcanzar un margen máximo de separación entre las clases, de esta manera cuando las nuevas muestras se ponen en correspondencia con dicho modelo, en función de su proximidad pueden ser clasificadas en una u otra clase.

El concepto de SVM, parte del problema de clasificación de dos clases usando modelos lineales de la forma

$$f(x) = W^T \varphi(x) + b \quad (2.3)$$

donde $\varphi(x)$ denota una transformación fija en el espacio de características X , y b el parámetro de sesgo [11]. Dado un conjunto de datos de entrenamiento

$$(x_1, y_1), \dots, (x_N, y_N), y_i \in \{-1, 1\} \quad (2.4)$$

el objetivo es encontrar una función $f(x)$ que separe las muestras positivas de la negativas (hiperplano de separación). Los puntos x que se encuentran en el hiperplano satisfacen (2.3) igualada a cero, donde w es normal al hiperplano y $\min\{b/|w|\}$ es la distancia mínima desde el hiperplano al origen y $|w|$ es la norma euclidiana de W . Suponiendo que el conjunto de datos de entrenamiento es linealmente separable en el espacio de características, por definición, existe al menos una elección de los parámetros w y b , tales que (2.3) satisface $f(x_i) > 0$ para los puntos que tienen $y_i = 1$ y $f(x_i) < 0$ para los puntos que tienen $y_i = -1$ [12].

2.6 Validación cruzada

Es una metodología ampliamente utilizada en la inteligencia artificial y en el aprendizaje de máquina cuando un mismo grupo de datos se usa para prueba y entrenamiento [13]. Conocida como k-folds, divide el conjunto de datos de forma aleatoria en k subconjuntos independientes de aproximadamente igual tamaño. Se efectúa el entrenamiento y prueba del modelo k veces, dejando fuera del entrenamiento un subconjunto diferente cada vez. Con este subconjunto se valida el funcionamiento del modelo entrenado con los $k - 1$ subconjuntos restantes. Los valores típicos de k suelen ser del orden de 5 a 20. Al término del proceso, se han aprovechado todos los datos disponibles para entrenar y validar el modelo. La estimación de la generalización del modelo es el promedio de las tasas de clasificación obtenidas con cada uno de los subconjuntos de prueba dando mayor robustez al sistema. El estimador obtenido no está sesgado, puesto que en cada resultado parcial no se usan los mismos datos para entrenar que para probar. Sin embargo, puede tener más varianza que otros métodos [14]. Cuando se entrenan varios modelos usando un conjunto de entrenamiento y se usa un segundo conjunto de datos (conjunto de validación) para decidir qué modelo es el mejor, se debe usar un tercer conjunto (conjunto de prueba o test) para obtener una estimación no sesgada del error de generalización del modelo elegido. También se puede, una vez elegido el modelo con los valores de los parámetros que funcionan mejor, entrenar de nuevo ese modelo con los conjuntos de entrenamiento y de validación juntos, y medir su capacidad de generalización [15].

2.7 Parámetros de medición del rendimiento de un clasificador

Para presentar los resultados de detección y, en general, para cualquier sistema de reconocimiento de patrones es común el uso de la matriz de contingencia o de confusión, que recoge el número de aciertos y fallos del sistema para cada una de las clases en que se divide el problema, dado un valor fijo del umbral de decisión

[14]. La siguiente tabla muestra la matriz de confusión en la que la suma de los elementos de cada fila debe ser igual a 100 por ciento (%).

Tabla 2.4 Matriz de Confusión

| | | Clase real | |
|----------------|---------|------------|---------|
| | | Clase 1 | Clase 0 |
| Clase estimada | Clase 1 | TP | FP |
| | Clase 0 | FN | TN |

De acuerdo con esta matriz y tomando como referencia la clase patológica, se definen los siguientes conceptos:

Detección correcta (TP, True Positive) El número o porcentaje de patrones de la clase 0 que el sistema clasifica correctamente como pertenecientes a la clase 0.

Falso rechazo (FN, False Negative) El número o porcentaje de patrones de la clase 0 que el sistema clasifica incorrectamente como pertenecientes a la clase 1.

Falsa aceptación (FP, False Positive) El número o porcentaje de patrones de la clase 1 que el sistema clasifica incorrectamente como pertenecientes a la clase 0.

Rechazo verdadero (TN, True Negative) El número o porcentajes de patrones de la clase 1 que un sistema clasifica correctamente como pertenecientes a la clase 1.

Nótese que cuando los valores se representan en porcentaje, $TP + FN = 100\%$ y $FP + TN = 100\%$; A partir de dichos valores, se pueden estimar:

Tasa de acierto o eficiencia (CCR, Correct Classification Rate) Es la proporción de patrones correctamente clasificados por el sistema.

$$CCR\% = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.5)$$

Tasa de error (ER, Error Rate) Es el complemento a la tasa de acierto, es decir, la proporción de patrones erradamente clasificados.

$$ERR\% = 100 - CCR\% \quad (2.6)$$

Idealmente, la tasa de acierto debería ser del 100 % y la tasa de error del 0 %. Aunque ambas medidas pueden usarse indistintamente, en tareas donde la tasa de acierto es muy alta se utiliza a menudo la tasa de error como indicador único. Si el número de patrones de las clases no están balanceados (no tienen el mismo número de patrones entre clases), el acierto y el error no reflejan realmente el funcionamiento del sistema, para corregir este problema se emplean estos otros parámetros:

Sensibilidad (S) Da una indicación de la capacidad del sistema para detectar los patrones de la clase de referencia. Cuando los valores se representan en porcentaje, la sensibilidad coincide con TP.

$$S = \frac{TP}{TP+FN} \quad (2.7)$$

Especificidad (E) Da una idea de la capacidad del sistema para rechazar los patrones que no pertenecen a la clase de referencia. Cuando los valores se representan en porcentaje, la especificidad coincide con TN.

$$E = \frac{TN}{TN+FP} \quad (2.8)$$

En el caso ideal, S y E deben ser 1 (o el 100 % si se miden en porcentaje).

2.8 Octave

GNU Octave es un lenguaje de alto nivel, destinado principalmente para cálculos numéricos. Proporciona una interfaz de línea de comando conveniente para resolver problemas lineales y no lineales numéricamente, y para realizar otros experimentos numéricos utilizando un lenguaje que es compatible con Matlab. También se puede usar como un lenguaje orientado a lotes. Octave tiene herramientas extensas para resolver problemas de álgebra lineal comunes,

encontrar las raíces de ecuaciones no lineales, integrar funciones ordinarias, manipular polinomios e integrar ecuaciones diferenciales y algebraicas ordinarias. Es fácilmente extensible y personalizable a través de funciones definidas por el usuario escritas en el propio lenguaje de Octave, o utilizando módulos cargados dinámicamente escritos en C ++, C, Python, Fortran u otros idiomas.

GNU Octave también es software libremente redistribuible. Puede redistribuirse y / o modificarse bajo los términos de la Licencia Pública General de GNU (GPL) publicada por la Free Software Foundation [16].

2.9 Python

Python es un lenguaje de programación de propósito general que comenzó como una solución para automatizar tareas de alto nivel en sistemas durante sus primeras fases. Sin embargo, pronto se hizo bastante famoso debido a su amplio soporte de desarrollo de aplicaciones. Permite crear sitios web con un backend, herramientas de GUI utilizando PyQt / Tkinter, predicción mediante el aprendizaje automático (bibliotecas como scikit-learn), análisis de datos utilizando módulos Pandas y desarrollo de juegos con PyGame.

Python es fácil de aprender, altamente legible y fácil de usar. Tiene una sintaxis limpia y en inglés que requiere menos codificación y permite que el programador se concentre en la lógica del problema en lugar de pensar en la esencia de la sintaxis [17]. Los Scripts desarrollados en Python son fácilmente integrables con Octave.

Capítulo 3

Metodología

3.1 Señales fonocardiográficas

Durante el desarrollo del trabajo se tuvo la necesidad de construir un repositorio de señales fonocardiográficas normales de personas adultas entre los 30 y 40 años de edad; de igual forma sonidos correspondientes a ruidos sistólicos y diastólicos sin patologías determinadas. En la web se encuentran señales correspondientes a S1 y S2 normales, afectadas por el sonido sistólico y por el sonido diastólico. Estas son de libre difusión y corresponden a archivos de sonido utilizadas para el entrenamiento de los médicos [18]. Estas señales son estándar a una frecuencia cardíaca determinada de 70 latidos por minuto que se considera normal dentro del ámbito médico. Para poder recrear un escenario cercano a la realidad se decidió contaminar las señales con ruido aditivo blanco gaussiano en diferentes relaciones de señal a ruido. La siguiente tabla muestra las diferentes SNR que se utilizó para contaminar las señales en cuestión:

Tabla 3.1 Ruidos de las señales de entrada y sus SNR

| Señal de entrada | Tipo de ruido | SNR Inicial dB | SNR Final dB | Intervalo dB |
|------------------|----------------|----------------|--------------|--------------|
| Normal | Aditivo Blanco | 10 | 100 | 10 |

| | | | | |
|-------------------|------------------|----|-----|----|
| | gaussiano | | | |
| Sistólico | Aditivo | 10 | 100 | 10 |
| | Blanco gaussiano | | | |
| Diastólico | Aditivo | 10 | 100 | 10 |
| | Blanco gaussiano | | | |

Tabla 3.2 Características de las señales de entrada

| | | |
|------------------------|------------|----------|
| Frecuencia de Muestreo | Fs | 11025 |
| Duración | mínima en | 0,72 seg |
| Segundos | | |
| Tipo de señal | Monofónica | |

A continuación se presentan las gráficas de las señales normalizadas (amplitud ajustada a la unidad) limpias y con sus correspondientes ruidos adicionados:

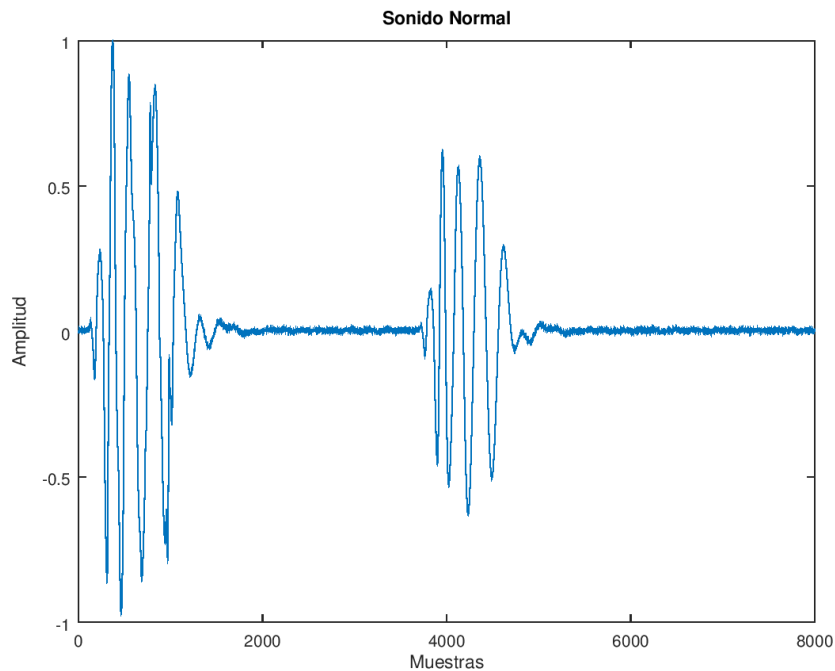


Figura 3. 1 Sonido normal sin ruido adicionado

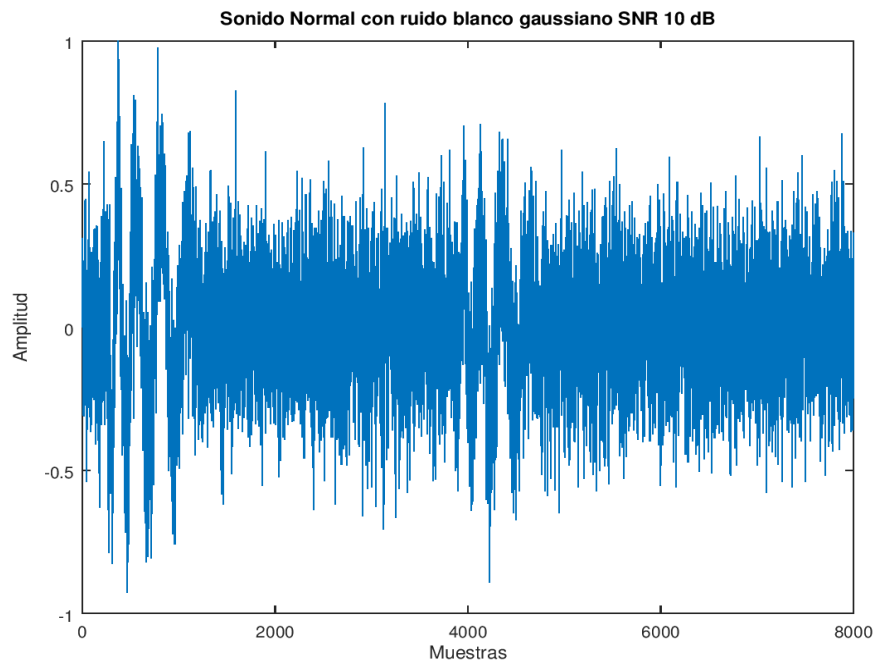


Figura 3. 2 Sonido normal con ruido blanco gaussiano adicionado SNR 10 dB

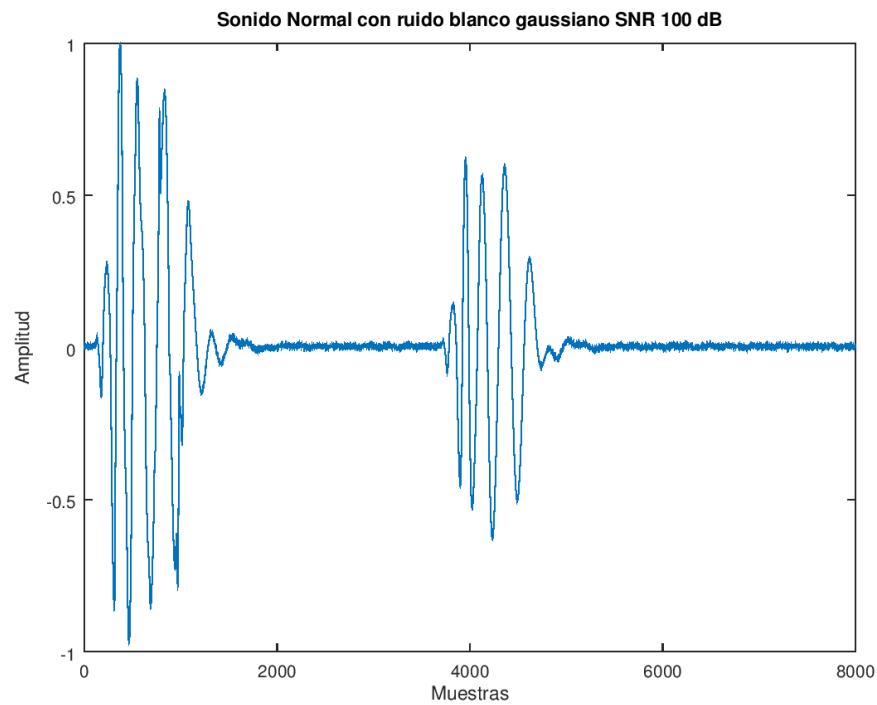


Figura 3. 3 Sonido normal con ruido blanco gaussiano adicionado SNR 100 dB

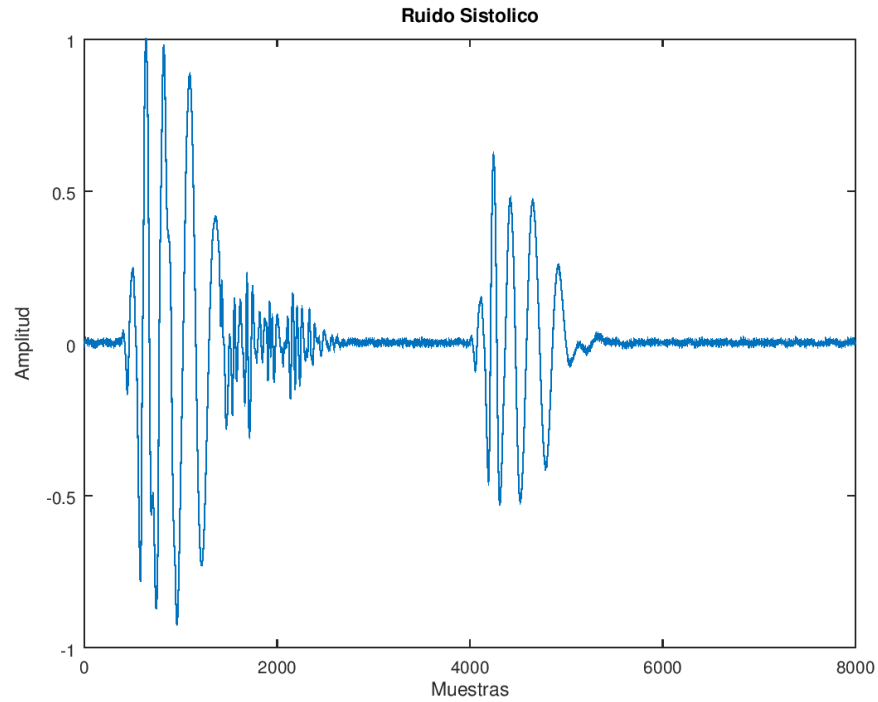


Figura 3. 4 Sonido sistólico sin ruido adicionado

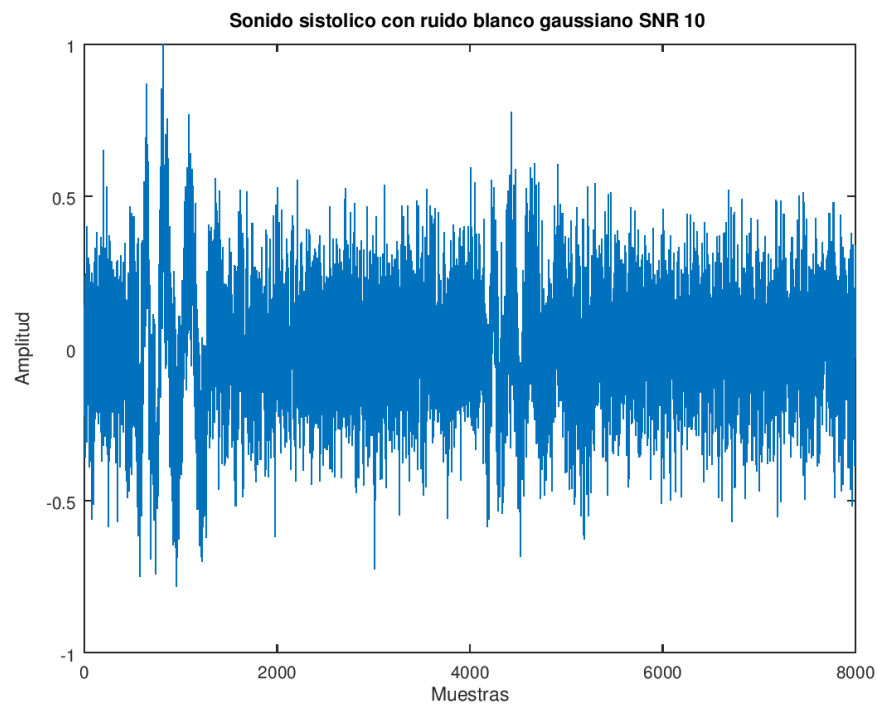


Figura 3. 5 Sonido sistólico con ruido blanco gaussiano adicionado SNR 10 dB

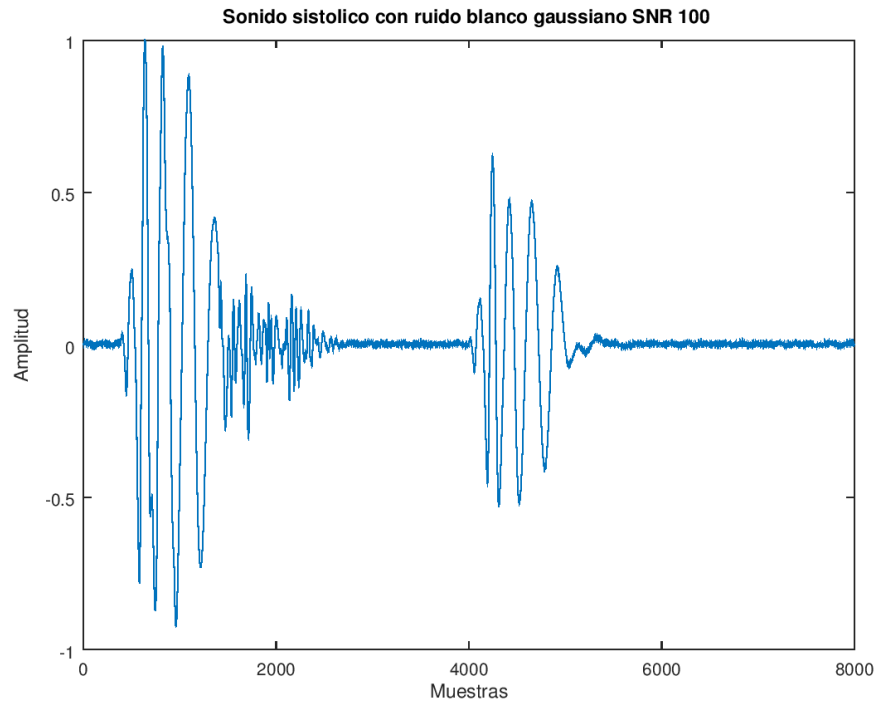


Figura 3. 6 Sonido sistólico con ruido blanco gaussiano adicionado SNR 100 dB

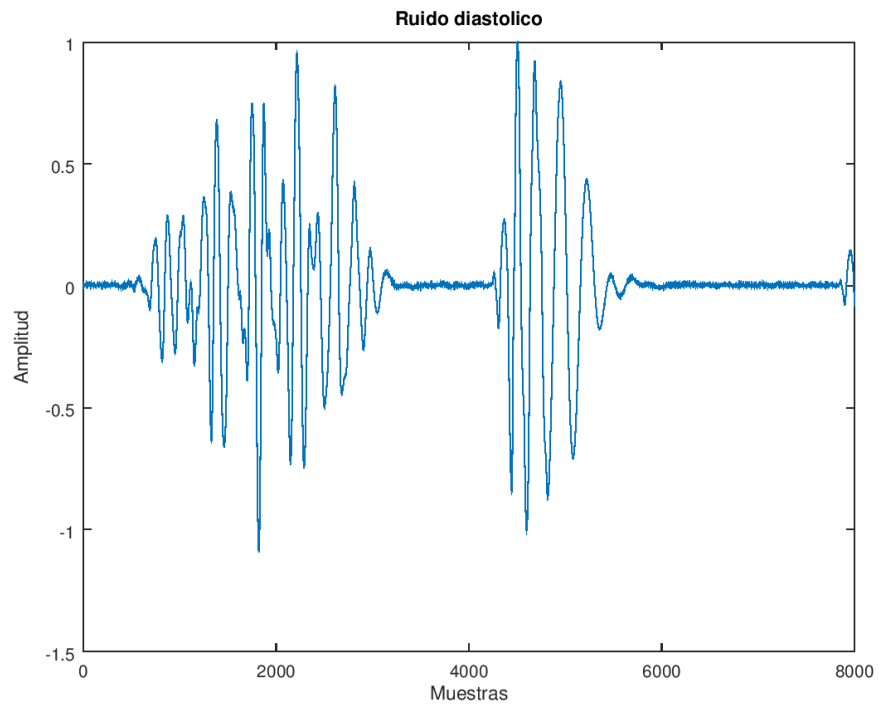


Figura 3. 7 Sonido diastólico sin ruido adicionado

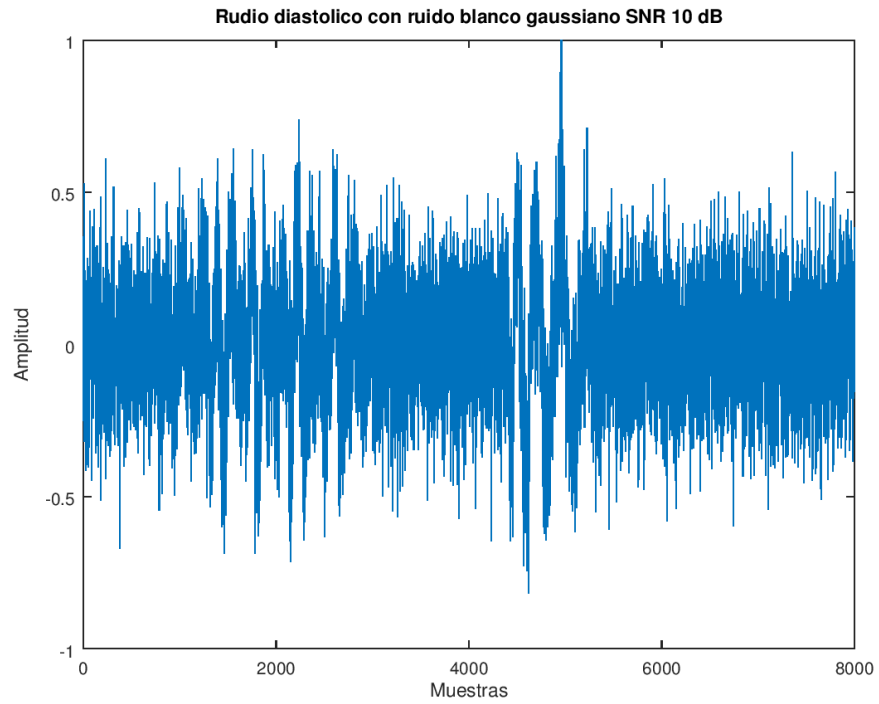


Figura 3. 8 Sonido diastólico con ruido blanco gaussiano adicionado SNR 10 dB

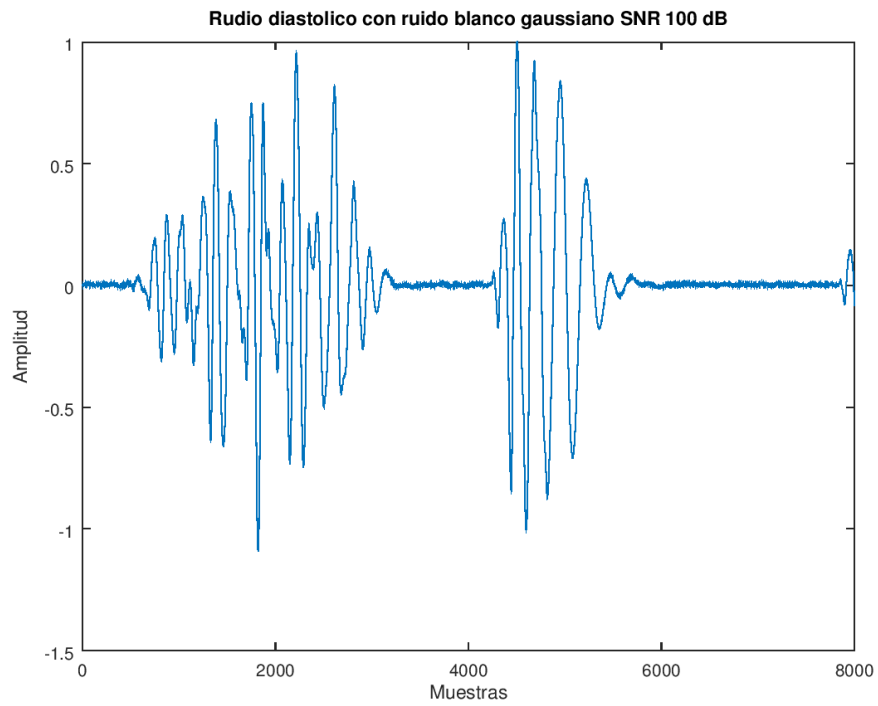


Figura 3. 9 Sonido diastólico con ruido blanco gaussiano adicionado SNR 100 dB

3.2 Extracción de características - Envoltente y clasificación

Con base en lo anterior se logró obtener un repositorio de 70 señales para cada uno de los sonidos en cuestión en diferentes relaciones señal a ruido. Estas fueron la base para el entrenamiento y validación de los clasificadores utilizados en los objetivos siguientes. Una vez construido el repositorio, se propone un modelo de extracción de características basado en la forma de la envoltente de cada una de las señales anteriormente mencionadas. Para ello se calcula la señal analítica de cada una y se procede a decimar la señal, esto con el fin de disminuir el número de muestras de la entrada para el clasificador. Es de notar que en el proceso de decimación hay una pérdida de información, por ese motivo se decide, a través de iteraciones estimar el valor de una variable de decimación k , de tal forma que el error de clasificación sea menor. A continuación se muestra el diagrama de bloques con el procedimiento mencionado:




Figura 3.10 Etapas de clasificación y validación

Etapa 1: Matriz de sonidos de entrada: Es necesario configurar una matriz con las señales que se van a utilizar para el entrenamiento y prueba del clasificador. Para ello se configuró una matriz de 200 filas por 8000 columnas, donde cada fila contiene las señales con y sin ruido. Ver Apéndice 1.

Etapa 2: Generación de Matriz de envoltentes: El objetivo es extraer las características de la matriz de la etapa anterior, por esa razón se calcula la envoltente de cada una de las filas que corresponden a las señales de entrada. Para esto se utiliza como herramienta la transformada de Hilbert mencionada en el capítulo 2. Ver Apéndice 2.

Etapa 3: Generación de Matriz de envolventes decimadas en un factor k . Esta etapa es muy importante ya que a través del método de iteraciones se encuentra un valor “ k ” tal que incida de menor manera en el error de clasificación; esto es encontrar un valor que permita obtener el menor número de muestras a la entrada del clasificador sin afectar significativamente la tasa de acierto. Ver Apéndice 3.

Etapa 4: Asignación de la etiqueta de clase. Este procedimiento es el más dispendioso ya que la asignación de etiquetas se realiza de manera manual para cada una de las clases. Se asigna el valor de uno (“1”) para la pertenencia y cero (“0”) para la no pertenencia. Es importante resaltar el cuidado que se debe tener en esta etapa debido a que el proceso de aprendizaje de los clasificadores utilizados es supervisado. Ver Apéndice 4.

Etapa 5. Validación 5-folds. Los parámetros para la caracterización de los clasificadores son Tasa de error, Tasa de acierto, Especificidad y Sensibilidad. En ese sentido se utiliza la técnica de validación k -folds, con k igual a 5 para, de esta manera probar el funcionamiento de los sistemas y lograr que los resultados obtenidos tengan la mayor veracidad posible. Para ello se divide el conjunto de datos en 5 grupos de los cuales 4 se utilizarán para entrenamiento y 1 para pruebas. El proceso se repite 5 veces dejando siempre un grupo por fuera para pruebas y los otros para el entrenamiento. El orden de cada uno de los elementos de cada grupo para cada iteración debe ser siempre aleatorio. Ver Apéndice 5.

3.3 Extracción de características – Imágenes y descriptor HOG

Ahora lo que se busca es observar el comportamiento de clasificación con un modelo de extracción de características de las señales fonocardiográficas mapeadas en una matriz de 172 por 320 con el propósito de tratar la señal como imagen. En ese sentido el mapeo lo que logra es configurar una función espacial $f(x, y)$ binaria, en la cual la función solo puede tomar dos valores 0 o 255 dependiendo de la señal de entrada. Una vez la matriz es configurada se procede a calcular el descriptor HOG que será el vector de características de entrada a los

clasificadores para nuevamente medir su desempeño. A continuación se presenta un diagrama de bloques con las etapas propuestas:

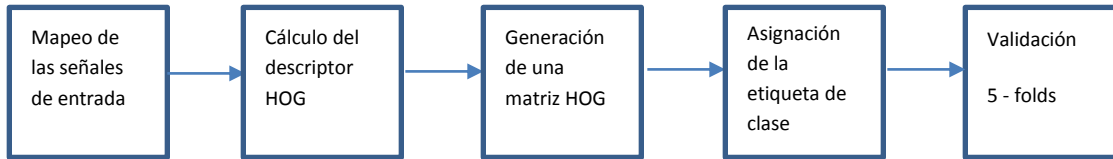


Figura 3.11 Etapas de mapeo y extracción de características de las señales como imágenes

Etapa 1. Mapeo de las señales de entrada. Con el objetivo de configurar como imágenes las señales temporales, se realizó un mapeo de estas en un arreglo bidimensional binario para, de esta manera obtener conjuntos de píxeles que representen la señal en cuestión. En ese sentido se generó una matriz tridimensional para cada una de las clases, donde cada capa es la imagen de sonidos normales, sistólicos o diastólicos con o sin ruido. Ver Apéndice 6.

Etapa 2. Cálculo del descriptor HOG. De las imágenes generadas a través del mapeo de señales es necesario extraer las características que serán usadas como entradas para el entrenamiento y prueba de los clasificadores. Por esta razón se decide usar las librerías de distribución elaboradas por Intel, las cuales tienen la función implementada y optimizada para el cálculo del histograma de orientación de los gradientes; estas son OpenCV para Python. Es muy importante resaltar que el uso de este descriptor permite la obtención de información espacial de la señal que está siendo estudiada. Ver Apéndice 7.

Etapa 3. Generación de una matriz HOG. De cada una de las capas obtenidas se obtiene un descriptor HOG, en ese sentido conviene una organización en forma de matriz de los vectores de características obtenidos. Es muy importante resaltar que la longitud de cada uno de estos arreglos es de 1764. Este es un valor constante que depende del número bloques y ventanas que se estén utilizando para el cálculo de este. Ver Apéndice 7.

Etapa 4. Asignación de etiquetas de clase. En la matriz HOG que tiene una dimensión de 200 filas por 1764 columnas se decide amentar una columna donde se etiquetará la pertenencia o no a una clase determinada. 1 indica pertenencia y

0 no pertenencia. La dimensión de la nueva matriz es 200 filas por 1765 columnas. Ver Apéndice 4.

Etapa 5. Validación 5 – folds. Se aplica el mismo procedimiento utilizado en la sección anterior. Ver Apéndice 5.

3.4 Extracción de características – Wavelets

Como último se propone usar un modelo de extracción de características basado en wavelets que a través del cálculo de los momentos estadísticos para cada una de las descomposiciones en N niveles permita configurar un vector que sirva de entrada para el entrenamiento y prueba de los clasificadores. Se decide calcular tres momentos, primero, segundo y segundo momento central. Las descomposiciones se aplicarán para las mismas señales utilizadas en las secciones anteriores.

A continuación se muestra el diagrama de bloques con las etapas propuestas:




Figura 3.12 Etapas de mapeo y extracción de características de las señales con Wavelets

Etapa 1. Descomposición wavelet en N niveles. Con base en la frecuencia de muestreo de las señales es conveniente realizar una descomposición en J-1 niveles, donde J corresponde a la potencia de 2 que se ajusta a la frecuencia de muestreo. Sin embargo se observa que para una descomposición – reconstrucción de 13 niveles el espectro es altamente correspondiente que el de la señal original. Por esta razón se decide usar N igual a 13 para la transformación wavelet. Es muy importante destacar que la ondita utilizada en esta etapa es la Daubechie 13

'db13', esto último como consecuencia de la revisión bibliográfica [19]. Ver Apéndice 8.

Etapa 2: Cálculo de los momentos estadísticos. Una vez se obtienen los vectores de coeficientes de aproximación y detalle en la etapa anterior se procede a calcular el primero, segundo y segundo momento central para cada uno de ellos. Esto se logra aplicando la identidad de Konig - Huygens [20]. Ver Apéndice 8.

Etapa 3: Configuración de vector de características Se organiza un vector de características de dimensión 1 por 42. Los doce primeros elementos corresponden a los primeros momentos de los N-1 vectores de coeficientes de detalle y del vector de aproximación. De igual forma los elementos siguientes corresponden a los segundos momentos y segundos momentos centrales respectivamente. Esto se hace para cada una de las señales obteniendo una matriz de características de 200 filas por 42 columnas. Ver Apéndice 8.

Etapa 4: Asignación de etiquetas de clase En la matriz de características obtenida en la etapa anterior de dimensión de 200 filas por 42 columnas se decide amentar una columna donde se etiquetará la pertenencia o no a una clase determinada. 1 indica pertenencia y 0 no pertenencia. La dimensión de la nueva matriz es 200 filas por 43 columnas. Ver Apéndice 4.

Etapa 5: Validación 5 – folds Se aplica el mismo procedimiento utilizado en la sección anterior. Ver Apéndice 5.

Capítulo 4

Resultados

Una vez aplicado el procedimiento para la obtención del valor de k mencionado en la etapa 3 de la figura 3.10 del capítulo anterior, se obtiene la siguiente gráfica:

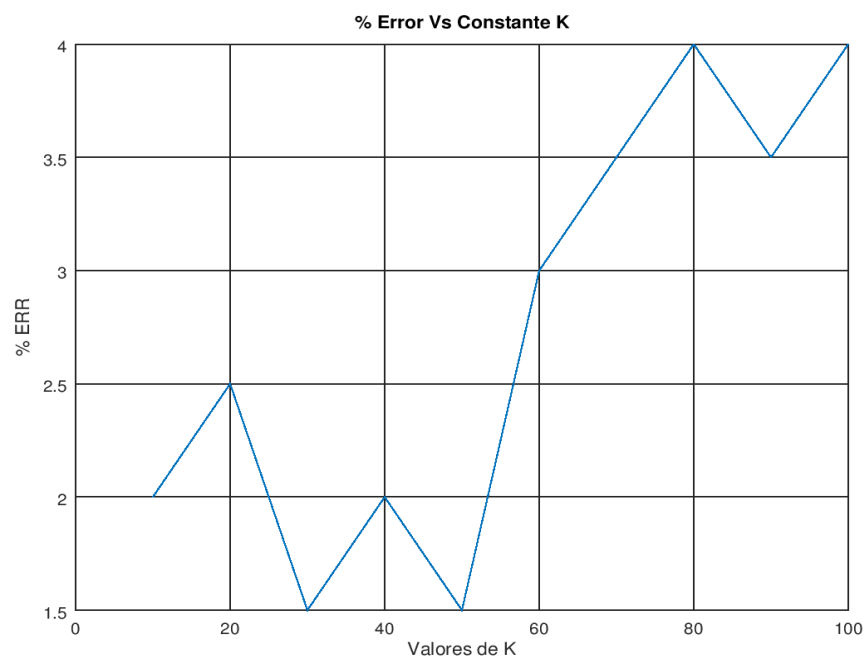


Figura 4.1 Porcentaje de error vs valor de la constante de decaimiento

En la figura 4.1 Se observa que para valores de k menores a 50, la variación del error se mantiene acotada en un intervalo definido de ancho 1%. Para valores mayores la pendiente es positiva generando una tasa de crecimiento que incrementa el error a medida que el valor de la constante de decaimiento aumenta.

Una vez determinado el valor de k para el cual se va a realizar la decimación de las señales, se ejecutan los procedimientos y se obtienen las siguientes gráficas que son un ejemplo secuencial de la extracción de características a través de la envolvente decimada para las tres clases de señales utilizadas con ruido y una SNR de 10 dB.

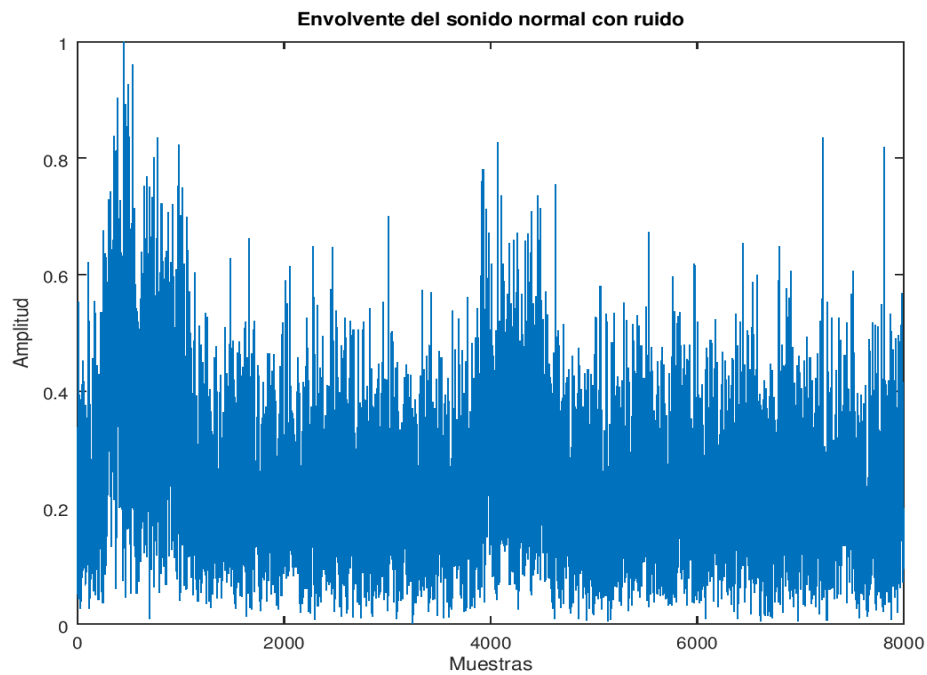


Figura 4. 2 Envolvente del Sonido Normal con ruido

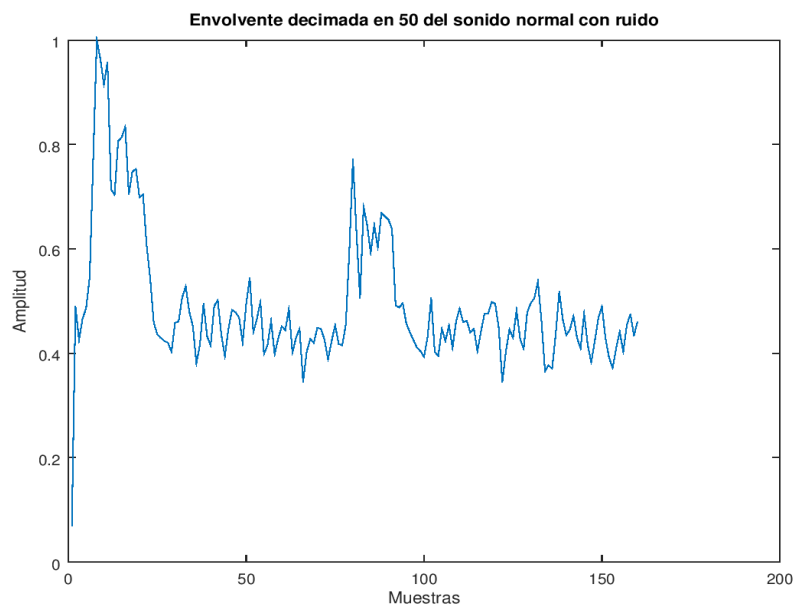


Figura 4.3 envolvente decimada en 50 del Sonido Normal con ruido

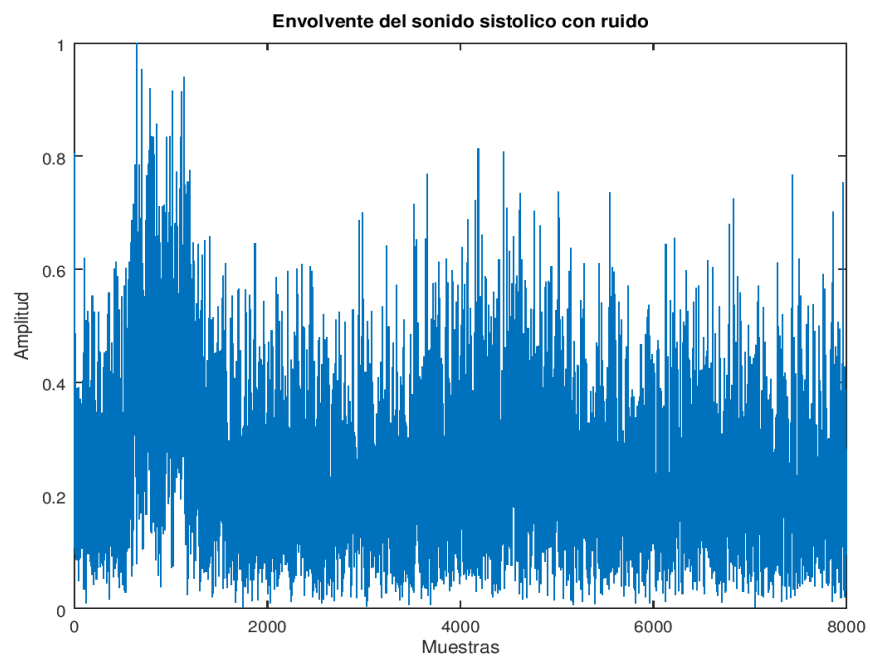


Figura 4. 4 Envolvente del Sonido Sistólico con ruido

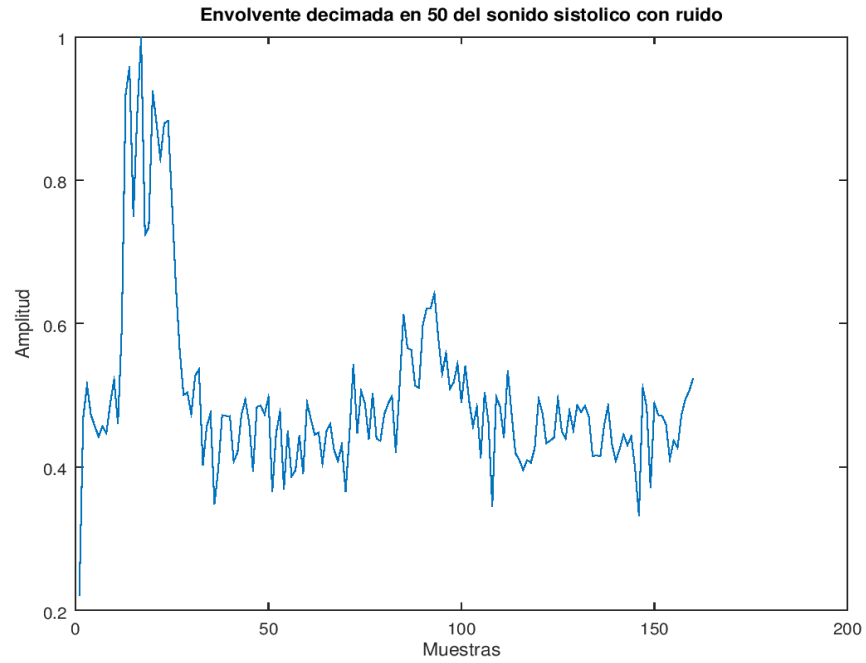


Figura 4. 5 Envolvente decimada en 50 del Sonido Sistólico con ruido

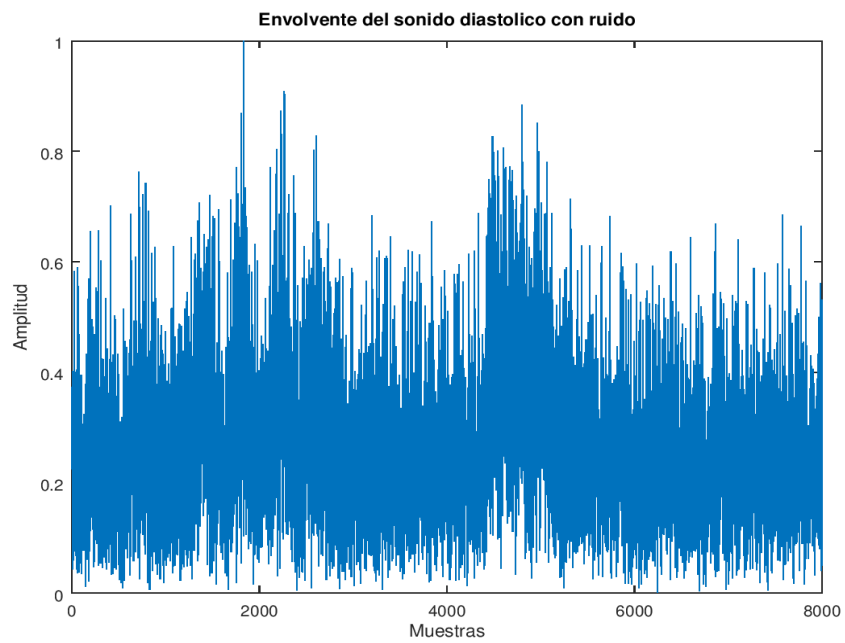


Figura 4. 6 Envolvente del Sonido Diastólico con ruido

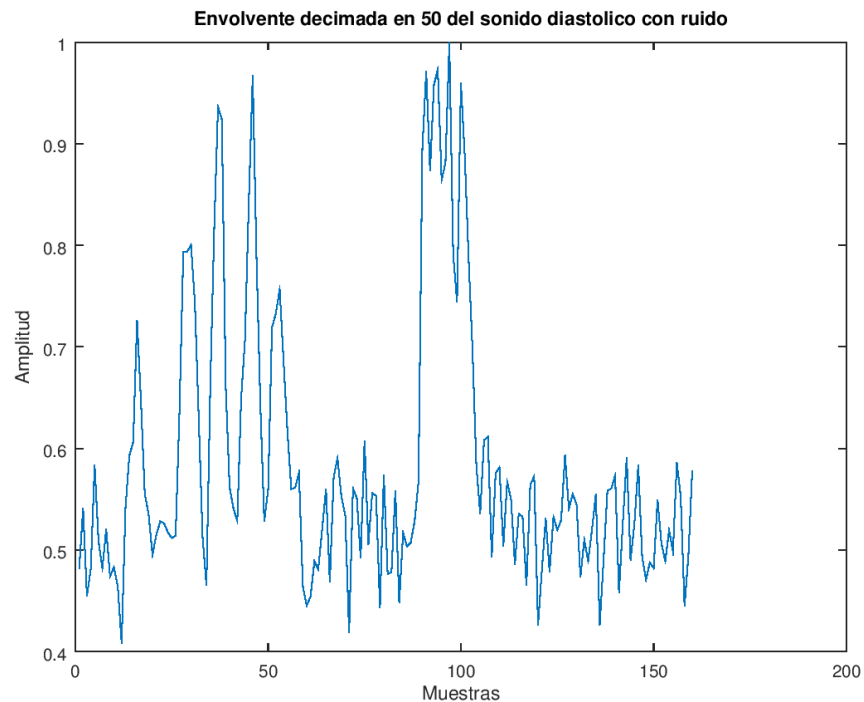


Figura 4. 7 Envolvente decimada en 50 del Sonido Diastólico con ruido

Las figuras 4.6 y 4.7 muestran las envolventes decimadas que constituyen las gráficas de los vectores de características utilizados para el entrenamiento y prueba de los clasificadores. Es de notar que la información se encuentra en la forma de la parte superior del eje horizontal (valores positivos) de la señal. La longitud de los vectores de características es 160.

Respecto a la extracción de características a través del descriptor HOG, de manera análoga se presentan unos ejemplos del mapeo de las diferentes señales con el fin de tratarlas como imágenes para, de esta manera poder aplicar el cálculo del histograma de orientación de los gradientes, sin embargo únicamente se mostrará las imágenes ya que el descriptor, que es el vector de características, constituye una abstracción de la figura en cuestión.




Figura 4. 8 Normal sin ruido adicionado




Figura 4. 9 Normal con ruido adicionado SNR 20 dB




Figura 4. 10 Normal con ruido adicionado SNR 10 dB

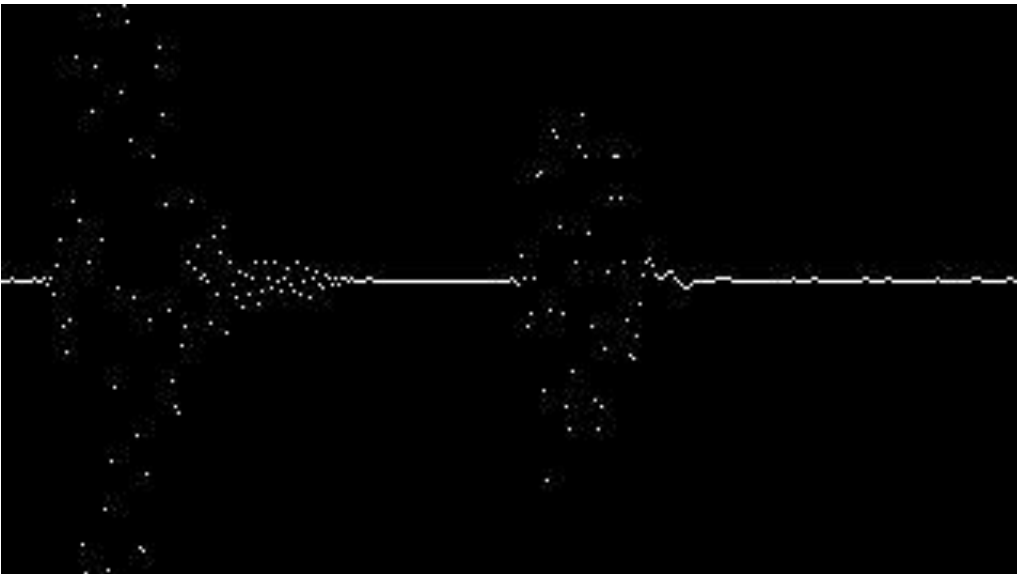


Figura 4. 11 Sistólico sin ruido adicionado




Figura 4. 12 Sistólico con ruido adicionado SNR 20 dB




Figura 4. 13 Sistólico con ruido adicionado SNR 10 dB




Figura 4. 14 Diastólico sin ruido adicionado




Figura 4. 15 Diastólico con ruido adicionado SNR 20 dB



Figura 4. 16 Diastólico con ruido adicionado SNR 10 dB

De las figuras 4.8 a la 4.16 se nota claramente la diferencia entre imágenes para cada clase, sin embargo para las señales con menor relación señal a ruido en los casos correspondientes al sonido normal y al sonido sistólico casi no hay diferencia influenciando directamente el error de clasificación.

Finalmente se aplica una descomposición Wavelet discreta de 13 niveles a cada una de las señales ruidosas y no ruidosas. Se obtuvo 13 vectores de detalle y un vector de aproximación para los cuales se calculó los momentos respectivos. A continuación se muestra la estructura del vector de características obtenido:

| Pimer Momento | | | | | | | | | | | | | Segundo Momento Central | | | | | | | | | | | | | Segundo Momento | | | | | | | | | | | | | | | |
|---------------|---|---|---|---|---|---|---|---|---|---|---|---|-------------------------|---|---|---|---|---|---|---|---|---|---|---|---|-----------------|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| A | D | D | D | D | D | D | D | D | D | D | D | D | A | D | D | D | D | D | D | D | D | D | D | D | D | A | D | D | D | D | D | D | D | D | D | D | D | D | | | |
| 1 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 0 | 1 | 2 | 3 | 1 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 0 | 1 | 2 | 3 | 1 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 0 | 1 | 2 | 3 |

Figura 4. 17 Estructura del vector de características conformado a través del cálculo de momentos estadísticos de la descomposición Wavelet

Se puede apreciar que los elementos sombreados con color azul son los primeros momentos correspondientes a las medias de cada uno de los vectores obtenidos en la descomposición, tanto de detalle como aproximación. En color amarillo los segundos momentos centrales que corresponden a las varianzas y en color verde

los segundos momentos. De igual forma se realizó una descomposición y reconstrucción de las señales con el fin de observar su comportamiento tiempo – escala. En las imágenes siguientes se muestra la descomposición por niveles y sus espectros, y la reconstrucción obtenida a partir de los vectores de aproximación y detalle:

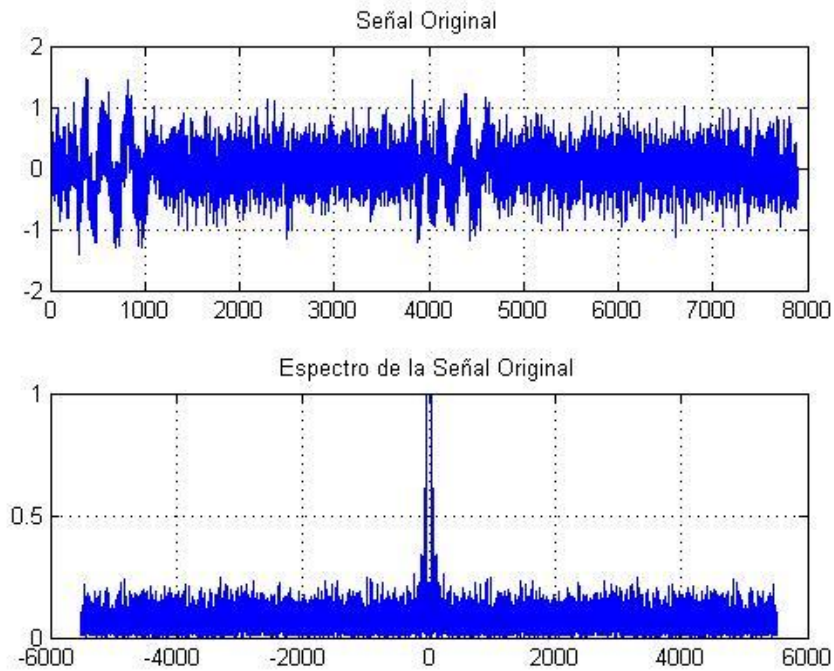


Figura 4. 18 Sonido normal y su espectro

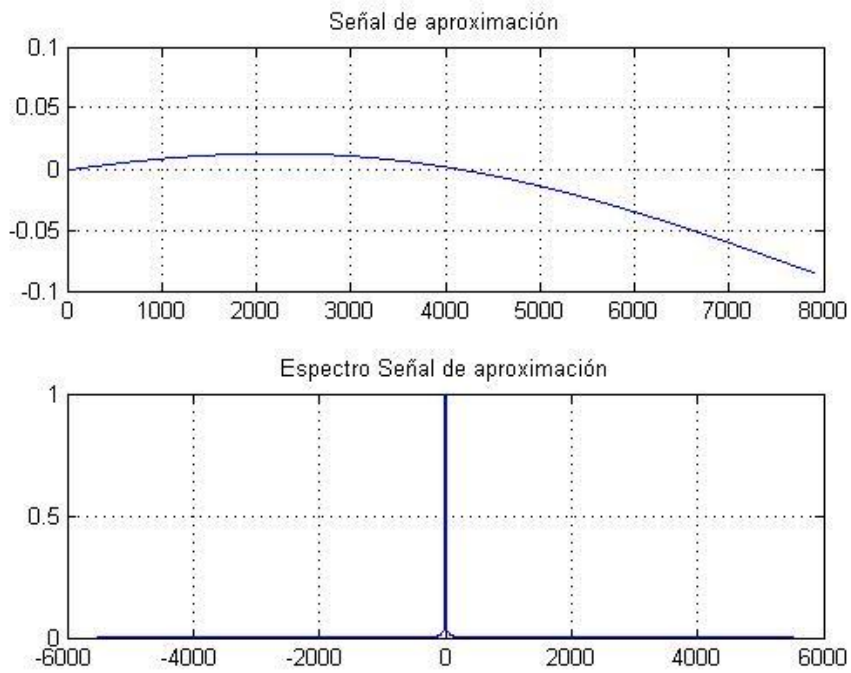


Figura 4. 19 Reconstrucción sonido normal con coeficientes de aproximación

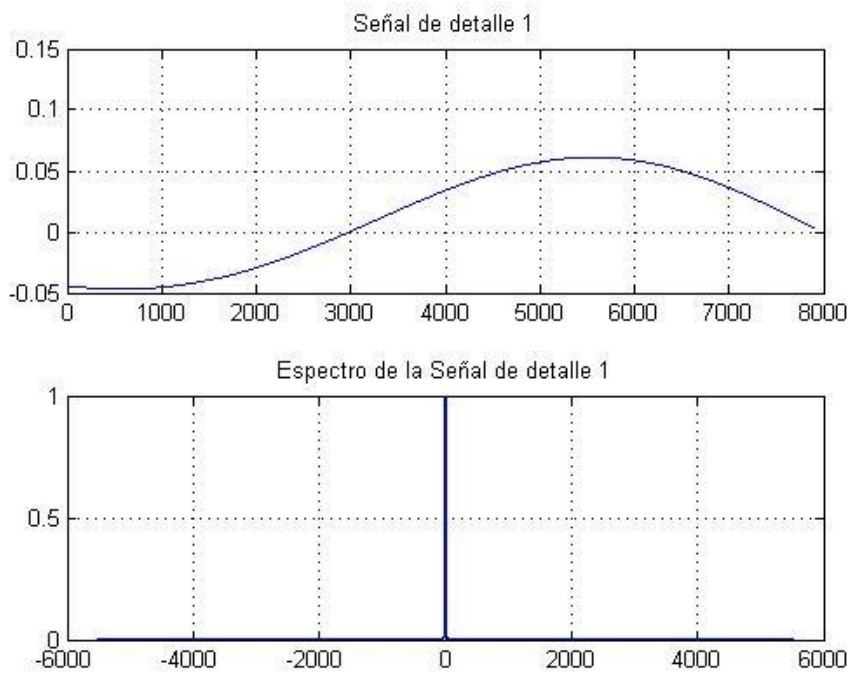


Figura 4. 20 Reconstrucción sonido normal con coeficientes de detalle 1




Figura 4. 21 Reconstrucción sonido normal con coeficientes de detalle 2




Figura 4. 22 Reconstrucción sonido normal con coeficientes de detalle 3




Figura 4. 23 Reconstrucción sonido normal con coeficientes de detalle 4




Figura 4. 24 Reconstrucción sonido normal con coeficientes de detalle 5




Figura 4. 25 Reconstrucción sonido normal con coeficientes de detalle 6




Figura 4. 26 Reconstrucción sonido normal con coeficientes de detalle 7




Figura 4. 27 Reconstrucción sonido normal con coeficientes de detalle 8




Figura 4. 28 Reconstrucción sonido normal con coeficientes de detalle 9




Figura 4. 29 Reconstrucción sonido normal con coeficientes de detalle 10




Figura 4. 30 Reconstrucción sonido normal con coeficientes de detalle 11




Figura 4. 31 Reconstrucción sonido normal con coeficientes de detalle 12




Figura 4. 32 Reconstrucción sonido normal con coeficientes de detalle 13

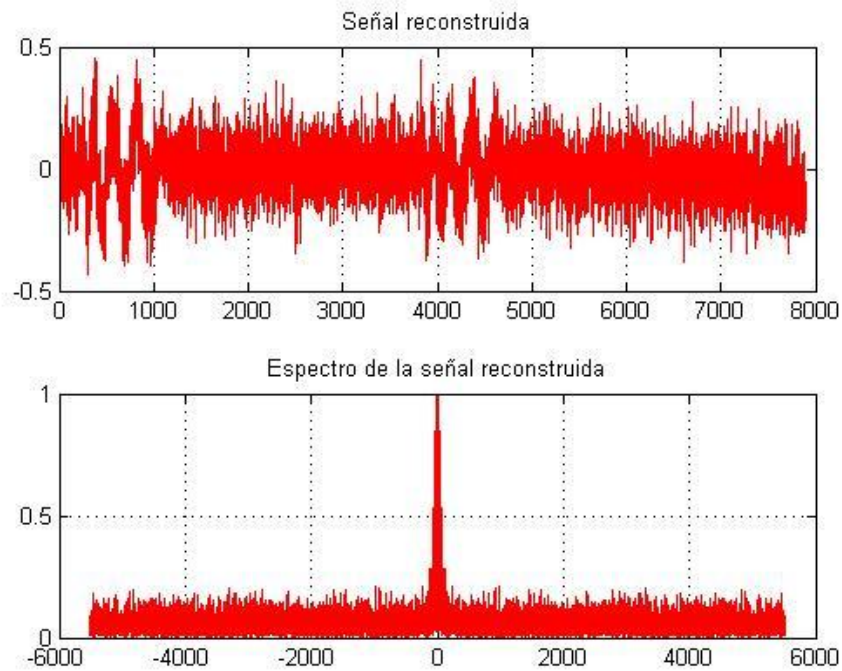


Figura 4. 33 Sonido normal reconstruido

De la figura 4.18 a la 4.32 se puede observar la secuencia de descomposición de la señal correspondiente a la clase normal. Fácilmente se aprecia que la señal reconstruida corresponde en gran medida con la señal original y de igual manera se nota que el espectro de las señales original y reconstruida tiene una gran correspondencia. Similarmente se observa que las señales correspondientes a la reconstrucción con los coeficientes de detalle 7 y 8 contienen información relevante debido a que aquí se muestran las componentes principales del sonido cardíaco. En este caso al ser una señal normal únicamente se aprecian los sonidos S1 y S2, sin embargo cuando una señal corresponde a una patología se debe observar un desdoblamiento de uno de los sonidos que se alargan en el tiempo generando lo que se conoce como soplo.

En las imágenes que siguen se mostrará la descomposición en wavelets de 13 niveles de sonidos cardíacos afectados por dos ruidos, uno en el ciclo sistólico y otro en el ciclo diastólico indicando diferentes patologías. Es de gran importancia resaltar que para estos ejemplos se ha utilizado señales contaminadas con ruido de manera intencional, sin embargo se notará que se produce un filtrado en los niveles más bajos.




Figura 4. 34 Sonido sistólico y su espectro




Figura 4. 35 Reconstrucción sonido sistólico con coeficientes de aproximación




Figura 4. 36 Reconstrucción sonido sistólico con coeficientes de detalle 1




Figura 4. 37 Reconstrucción sonido sistólico con coeficientes de detalle 2




Figura 4. 38 Reconstrucción sonido sistólico con coeficientes de detalle 3




Figura 4. 39 Reconstrucción sonido sistólico con coeficientes de detalle 4




Figura 4. 40 Reconstrucción sonido sistólico con coeficientes de detalle 5




Figura 4. 41 Reconstrucción sonido sistólico con coeficientes de detalle 6




Figura 4. 42 Reconstrucción sonido sistólico con coeficientes de detalle 7




Figura 4. 43 Reconstrucción sonido sistólico con coeficientes de detalle 8

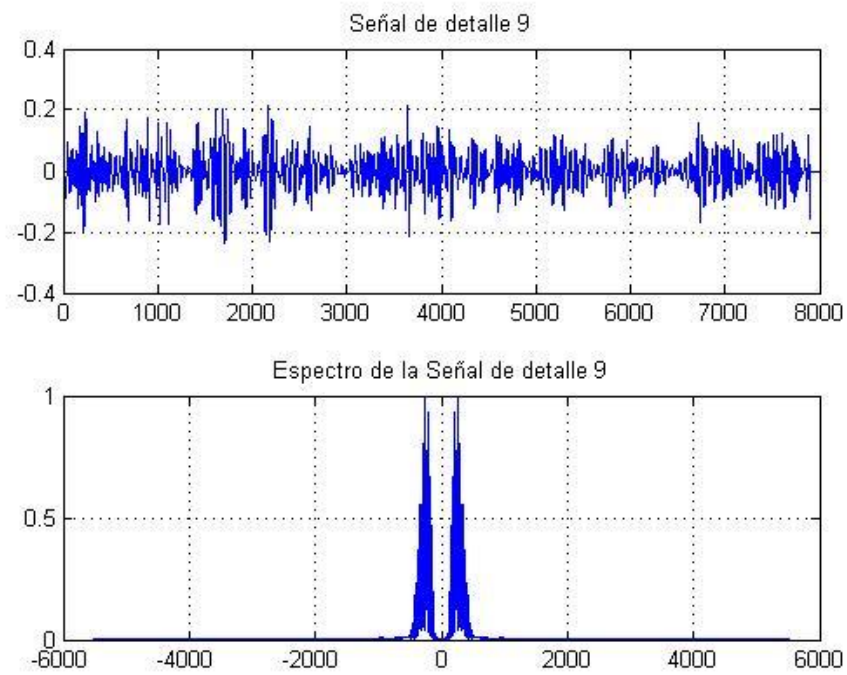


Figura 4. 44 Reconstrucción sonido sistólico con coeficientes de detalle 9




Figura 4. 45 Reconstrucción sonido sistólico con coeficientes de detalle 10

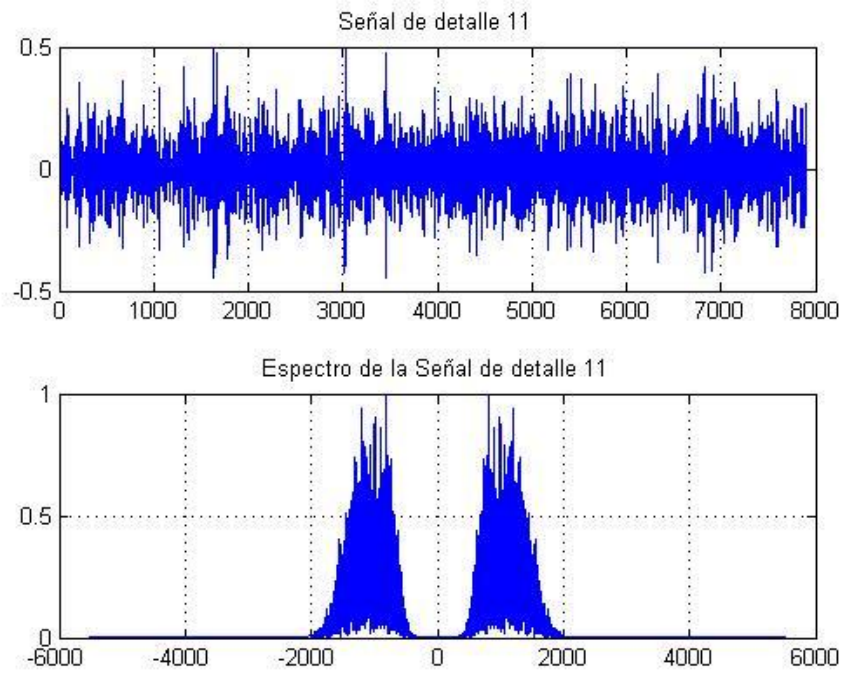


Figura 4. 46 Reconstrucción sonido sistólico con coeficientes de detalle 11




Figura 4. 47 Reconstrucción sonido sistólico con coeficientes de detalle 12




Figura 4. 48 Reconstrucción sonido sistólico con coeficientes de detalle 13




Figura 4. 49 Sonido sistólico reconstruido




Figura 4. 50 Sonido diastólico y su espectro




Figura 4. 51 Reconstrucción sonido diastólico con coeficientes de aproximación




Figura 4. 52 Reconstrucción sonido diastólico con coeficientes de detalle 1




Figura 4. 53 Reconstrucción sonido diastólico con coeficientes de detalle 2




Figura 4. 54 Reconstrucción sonido diastólico con coeficientes de detalle 3




Figura 4. 55 Reconstrucción sonido diastólico con coeficientes de detalle 4




Figura 4. 56 Reconstrucción sonido diastólico con coeficientes de detalle 5




Figura 4. 57 Reconstrucción sonido diastólico con coeficientes de detalle 6




Figura 4. 58 Reconstrucción sonido diastólico con coeficientes de detalle 7




Figura 4. 59 Reconstrucción sonido diastólico con coeficientes de detalle 8




Figura 4. 60 Reconstrucción sonido diastólico con coeficientes de detalle 9




Figura 4. 61 Reconstrucción sonido diastólico con coeficientes de detalle 10




Figura 4. 62 Reconstrucción sonido diastólico con coeficientes de detalle 11




Figura 4. 63 Reconstrucción sonido diastólico con coeficientes de detalle 12




Figura 4. 64 Reconstrucción sonido diastólico con coeficientes de detalle 13




Figura 4. 65 Reconstrucción del sonido diastólico

Las figuras 4.35 a la 4.48 corresponden a la descomposición - reconstrucción wavelet de una señal fonocardiográfica del tipo sistólico, en las reconstrucciones de nivel 7 y 8 se aprecia en mayor medida la existencia de este ruido y aportan gran información para la diferenciación en el proceso de clasificación. De igual forma las figuras de la 4.51 a la 4.64 muestran la descomposición – reconstrucción de una señal del tipo diastólico.

Una vez obtenidos las matrices de características para cada caso se procede a validar los clasificadores a través de la metodología K-Folds y se calcula los parámetros de desempeño: tasa de acierto, tasa de error, sensibilidad y especificidad. Esto se hace para cada una de las clases y con dos modelos de clasificación: SVM y ANN

Tabla 4.1 Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características envolvente decimada. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Normal

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 87,50% | 12,50% | 88,46% | 85,71% |
| 2 | 97,50% | 2,50% | 100,00% | 80,00% |
| 3 | 100,00% | 0,00% | 100,00% | 100,00% |
| 4 | 92,50% | 7,50% | 92,86% | 91,67% |
| 5 | 90,00% | 10,00% | 96,77% | 66,67% |
| Promedio | 93,50% | 6,50% | 95,62% | 84,81% |

Tabla 4.2 Parámetros de rendimiento de un clasificador tipo (ANN) con modelo de extracción de características envolvente decimada. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Normal

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 92,50% | 7,50% | 96,97% | 71,43% |
| 2 | 87,50% | 12,50% | 88,00% | 86,67% |
| 3 | 92,50% | 7,50% | 100,00% | 85,71% |
| 4 | 90,00% | 10,00% | 92,86% | 83,33% |
| 5 | 77,50% | 22,50% | 78,26% | 76,47% |
| Promedio | 88,00% | 12,00% | 91,22% | 80,72% |

En las tablas 4.1 y 4.2 se observa el desempeño de los clasificadores con el modelo de extracción de características basado en la envolvente decimada de las señales, de aquí se obtiene que la máquina de soporte vectorial tuvo mejores resultados de desempeño en cuanto a tasa de acierto, sensibilidad y especificidad, esto para la prueba y validación de la clase normal. La diferencia de tasas de acierto es de 5.5 puntos.

Tabla 4.3 Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características envolvente decimada. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Sistólico

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 95,00% | 5,00% | 94,74% | 95,24% |
| 2 | 87,50% | 12,50% | 87,50% | 87,50% |
| 3 | 97,50% | 2,50% | 100,00% | 93,75% |
| 4 | 97,50% | 2,50% | 100,00% | 92,31% |
| 5 | 92,50% | 7,50% | 96,67% | 80,00% |
| Promedio | 94,00% | 6,00% | 95,78% | 89,76% |

Tabla 4.4 Parámetros de rendimiento de un clasificador tipo (ANN) con modelo de extracción de características envolvente decimada. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Sistólico

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 87,50% | 12,50% | 88,46% | 85,71% |
| 2 | 92,50% | 7,50% | 92,86% | 91,67% |
| 3 | 95,00% | 5,00% | 96,55% | 90,91% |
| 4 | 87,50% | 12,50% | 85,00% | 90,00% |
| 5 | 87,50% | 12,50% | 93,75% | 62,50% |
| Promedio | 90,00% | 10,00% | 91,32% | 84,16% |

Las tablas 4.3 y 4.4 Para la clase Sistólico igualmente la máquina de soporte vectorial tuvo mejores resultados de desempeño, sin embargo ahora la brecha de las tasas de acierto se disminuye en 1.5 puntos. Observe que el rendimiento del clasificador ANN mejora respecto a la clase Normal.

Tabla 4.5 Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características envolvente decimada. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Diastólico

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 95,00% | 5,00% | 96,15% | 92,86% |
| 2 | 97,50% | 2,50% | 100,00% | 95,24% |
| 3 | 100,00% | 0,00% | 100,00% | 100,00% |
| 4 | 97,50% | 2,50% | 96,67% | 100,00% |
| 5 | 92,50% | 7,50% | 92,86% | 92,31% |
| Promedio | 96,50% | 3,50% | 97,14% | 96,08% |

Tabla 4.6 Parámetros de rendimiento de un clasificador tipo (ANN) con modelo de extracción de características envolvente decimada. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Diastólico

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 92,50% | 7,50% | 93,33% | 90,00% |
| 2 | 95,00% | 5,00% | 95,00% | 95,00% |
| 3 | 100,00% | 0,00% | 100,00% | 100,00% |
| 4 | 92,50% | 7,50% | 90,91% | 94,44% |
| 5 | 87,50% | 12,50% | 83,33% | 90,91% |
| Promedio | 93,50% | 6,50% | 92,52% | 94,07% |

Para la clase Diastólico el desempeño de los clasificadores mejora notablemente, sin embargo la brecha entre el clasificador basado en máquina de soporte vectorial presenta mejores resultados que la red neuronal. Ahora la brecha de tasas de error es de 3 puntos.

Tabla 4.7 Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características descriptor HOG. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Normal

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 90,00% | 10,00% | 92,00% | 86,67% |
| 2 | 92,50% | 7,50% | 94,12% | 83,33% |
| 3 | 97,50% | 2,50% | 94,44% | 100,00% |
| 4 | 97,50% | 2,50% | 100,00% | 93,75% |
| 5 | 97,50% | 2,50% | 100,00% | 85,71% |
| Promedio | 95,00% | 5,00% | 96,11% | 89,89% |

Tabla 4.8 Parámetros de rendimiento de un clasificador tipo (ANN) con modelo de extracción de características descriptor HOG. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Normal

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 90,00% | 10,00% | 92,59% | 84,62% |
| 2 | 92,50% | 7,50% | 85,71% | 96,15% |
| 3 | 95,00% | 5,00% | 97,14% | 80,00% |
| 4 | 97,50% | 2,50% | 100,00% | 95,83% |
| 5 | 97,50% | 2,50% | 100,00% | 96,15% |
| Promedio | 94,50% | 5,50% | 95,09% | 90,55% |

En este caso se cambia el modelo de extracción de características por el descriptor HOG y se observa una notable mejora en el desempeño de los clasificadores. Observe que el error de clasificación en comparación con el modelo basado en envolvente decimada disminuye en 1.5 puntos para el caso de la máquina de soporte vectorial y 6.5 puntos para el caso red neuronal, de igual forma la sensibilidad del clasificador tipo ANN supera al basado en SVM. Sin embargo el desempeño en terminos generales de la máquina de soporte vectorial es mejor, todo esto para la clase Normal.

Tabla 4.9 Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características descriptor HOG. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Sistólico

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 90,00% | 10,00% | 94,12% | 86,96% |
| 2 | 100,00% | 0,00% | 100,00% | 100,00% |
| 3 | 97,50% | 2,50% | 95,45% | 100,00% |
| 4 | 95,00% | 5,00% | 95,83% | 93,75% |
| 5 | 97,50% | 2,50% | 100,00% | 95,24% |
| Promedio | 96,00% | 4,00% | 97,08% | 95,19% |

Tabla 4.10 Parámetros de rendimiento de un clasificador tipo (ANN) con modelo de extracción de características descriptor HOG. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Sistólico

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 85,00% | 15,00% | 95,00% | 75,00% |
| 2 | 95,00% | 5,00% | 95,65% | 94,12% |
| 3 | 97,50% | 2,50% | 96,00% | 100,00% |
| 4 | 97,50% | 2,50% | 100,00% | 87,50% |
| 5 | 100,00% | 0,00% | 100,00% | 100,00% |
| Promedio | 95,00% | 5,00% | 97,33% | 91,32% |

De igual forma para la clase Sistólico se observa un comportamiento en el cual el error de clasificación disminuye en 2 puntos para el clasificador SVM y en 7.5 puntos para la red neuronal. Los parámetros de sensibilidad son similares, sin embargo la especificidad es superior en la máquina de soporte vectorial, cerca de 4 puntos por encima de los resultados obtenidos para la ANN.

Tabla 4.11 Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características descriptor HOG. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Diastólico

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 97,50% | 2,50% | 93,33% | 100,00% |
| 2 | 100,00% | 0,00% | 100,00% | 100,00% |
| 3 | 97,50% | 2,50% | 95,65% | 100,00% |
| 4 | 97,50% | 2,50% | 100,00% | 94,74% |
| 5 | 95,00% | 5,00% | 97,37% | 50,00% |
| Promedio | 97,50% | 2,50% | 97,27% | 88,95% |

Tabla 4.12 Parámetros de rendimiento de un clasificador tipo (ANN) con modelo de extracción de características descriptor HOG. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Diastólico

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 100,00% | 0,00% | 100,00% | 100,00% |
| 2 | 97,50% | 2,50% | 100,00% | 94,74% |
| 3 | 97,50% | 2,50% | 97,44% | 100,00% |
| 4 | 97,50% | 2,50% | 100,00% | 97,30% |
| 5 | 100,00% | 0,00% | 100,00% | 100,00% |
| Promedio | 98,50% | 1,50% | 99,49% | 98,41% |

Para la clase Diastólico se observan mejores resultados para el clasificador tipo red neuronal, superando la máquina de soporte vectorial en 1 punto respecto a la tasa de acierto. Del mismo modo en terminos de sensibilidad y especificidad presenta mejores resultados estableciendo un brecha de 9.46 puntos en el caso del último parámetro mencionado. Respecto al modelo de extracción de características basado en la envolvente decimada el desempeño mejora de manera notoria.

Tabla 4.13 Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características Wavelets. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Normal

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 95,00% | 5,00% | 95,83% | 93,75% |
| 2 | 95,00% | 5,00% | 96,97% | 85,71% |
| 3 | 97,50% | 2,50% | 94,44% | 100,00% |
| 4 | 100,00% | 0,00% | 100,00% | 100,00% |
| 5 | 97,50% | 2,50% | 100,00% | 85,71% |
| Promedio | 97,00% | 3,00% | 97,45% | 93,04% |

Tabla 4.14 Parámetros de rendimiento de un clasificador tipo ANN con modelo de extracción de características Wavelets. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Normal

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 95,00% | 5,00% | 96,15% | 92,86% |
| 2 | 97,50% | 2,50% | 100,00% | 96,43% |
| 3 | 97,50% | 2,50% | 97,14% | 100,00% |
| 4 | 100,00% | 0,00% | 100,00% | 100,00% |
| 5 | 97,50% | 2,50% | 100,00% | 96,15% |
| Promedio | 97,50% | 2,50% | 98,66% | 97,09% |

Aplicando el modelo de extracción de características basado en wavelets se observa que la ANN tiene mejor desempeño que la máquina de soporte vectorial para la clase normal. Es de notar que el error disminuye respecto a los otros modelos de extracción de características propuestos obteniendo mejores resultados en la tasa de acierto, inclusive por encima de 2 puntos.

Tabla 4.15 Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características Wavelets. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Sistólico

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 97,50% | 2,50% | 100,00% | 95,83% |
| 2 | 100,00% | 0,00% | 100,00% | 100,00% |
| 3 | 97,50% | 2,50% | 95,45% | 100,00% |
| 4 | 97,50% | 2,50% | 96,00% | 100,00% |
| 5 | 97,50% | 2,50% | 95,00% | 100,00% |
| Promedio | 98,00% | 2,00% | 97,29% | 99,17% |

Tabla 4.16 Parámetros de rendimiento de un clasificador tipo ANN con modelo de extracción de características Wavelets. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Sistólico

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 97,50% | 2,50% | 95,00% | 100,00% |
| 2 | 97,50% | 2,50% | 95,65% | 100,00% |
| 3 | 97,50% | 2,50% | 96,00% | 100,00% |
| 4 | 100,00% | 0,00% | 100,00% | 100,00% |
| 5 | 97,50% | 2,50% | 100,00% | 94,12% |
| Promedio | 98,00% | 2,00% | 97,33% | 98,82% |

De igual forma para la clase sistólico se obtienen resultados satisfactorios; la ANN presenta menor error de clasificación comparado con los otros dos métodos de extracción de características. Sin embargo en comparación a la máquina de soporte vectorial el desempeño es similar. Por otra parte en términos de especificidad la ANN supera en 1 punto a la SVM.

Tabla 4.17 Parámetros de rendimiento de un clasificador tipo SVM con modelo de extracción de características Wavelets. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Diastólico

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 97,50% | 2,50% | 93,33% | 100,00% |
| 2 | 100,00% | 0,00% | 100,00% | 100,00% |
| 3 | 100,00% | 0,00% | 100,00% | 100,00% |
| 4 | 100,00% | 0,00% | 100,00% | 100,00% |
| 5 | 97,50% | 2,50% | 100,00% | 66,67% |
| Promedio | 99,00% | 1,00% | 98,67% | 93,33% |

Tabla 4.18 Parámetros de rendimiento de un clasificador tipo ANN con modelo de extracción de características Wavelets. Datos obtenidos bajo la metodología K-Folds para la clase Sonido Diastólico

| Iteración | CCR % | ERR % | Sensibilidad | Especificidad |
|------------------|--------------|--------------|---------------------|----------------------|
| 1 | 100,00% | 0,00% | 100,00% | 100,00% |
| 2 | 97,50% | 2,50% | 100,00% | 94,74% |
| 3 | 100,00% | 0,00% | 100,00% | 100,00% |
| 4 | 97,50% | 2,50% | 100,00% | 97,30% |
| 5 | 100,00% | 0,00% | 100,00% | 100,00% |
| Promedio | 99,00% | 1,00% | 100,00% | 98,41% |

Finalmente para la clase Diastólico se obtienen los mejores resultados tanto para el clasificador SVM como para el ANN. Es de notar que la tasa de acierto aumenta hasta un 99% y los parámetros de sensibilidad y especificidad son cercanos al 100%. A continuación se presenta una tabla resumen con los mejores resultados obtenidos en la comparación del desempeño de los clasificadores:

Tabla 4.19 Resumen del desempeño de los clasificadores

| Modelo de extracción de características | Clasificador | Clase | CCR% | ERR% | Sensibilidad | Especificidad |
|--|---------------------|--------------|-------------|-------------|---------------------|----------------------|
| Env Dec | SVM | Normal | 93,5 | 6,5 | 95,62 | 84,81 |
| Env Dec | ANN | Normal | 88 | 12 | 91,22 | 80,72 |
| Env Dec | SVM | Sistólico | 94 | 6 | 95,78 | 89,76 |
| Env Dec | ANN | Sistólico | 90 | 10 | 91,32 | 84,16 |
| Env Dec | SVM | Diastólico | 96,5 | 3,5 | 94,14 | 96,08 |
| Env Dec | ANN | Diastólico | 93,5 | 6,5 | 95,52 | 94,07 |
| HOG | SVM | Normal | 95 | 5 | 96,11 | 89,29 |
| HOG | ANN | Normal | 94,5 | 5,5 | 95,09 | 96,55 |
| HOG | SVM | Sistólico | 96 | 4 | 97,08 | 95,19 |
| HOG | ANN | Sistólico | 95 | 5 | 97,33 | 91,32 |
| HOG | SVM | Diastólico | 97,5 | 2,5 | 97,27 | 88,95 |
| HOG | ANN | Diastólico | 98,5 | 1,5 | 99,49 | 98,47 |

| | | | | | | |
|----------------|-----|------------|------|-----|-------|-------|
| Wavelet | SVM | Normal | 97 | 3 | 97,45 | 93,04 |
| Wavelet | ANN | Normal | 97,5 | 2,5 | 98,66 | 97,09 |
| Wavelet | SVM | Sistólico | 98 | 2 | 97,29 | 99,17 |
| Wavelet | ANN | Sistólico | 98 | 2 | 97,33 | 98,82 |
| Wavelet | SVM | Diastólico | 99 | 1 | 98,67 | 93,33 |
| Wavelet | ANN | Diastólico | 99 | 1 | 100 | 98,41 |

A continuación se presenta los resultados más relevantes, donde se organizó los clasificadores y su modelo de extracción de características con base a los mejores y peores desempeños obtenidos por clase:

Para la clase Normal el mejor clasificador es del tipo ANN con modelo de extracción de características Wavelet; obtuvo 97% de tasa de acierto, 98.66% de sensibilidad y 97.09 de especificidad.

Para la clase Sistólico el mejor clasificador es del tipo SVM con modelo de extracción de características Wavelet; obtuvo 98% de tasa de acierto, 97.29% de sensibilidad y 99.17% de especificidad.

Para la clase Diastólico el mejor clasificador es del tipo ANN con modelo de extracción de características Wavelet; obtuvo 99% de tasa de acierto, 100 % de sensibilidad y 98.41 % especificidad.

En contraposición para la clase Normal el clasificador que tuvo el peor desempeño es del tipo ANN con modelo de extracción de características Envolverte Decimada; obtuvo 80% de tasa de acierto, 91.22% de sensibilidad y 80.72% de especificidad.

Para la clase Sistólico el clasificador que tuvo el peor desempeño es del tipo ANN con modelo de extracción de características Envolverte Decimada; obtuvo 90% de tasa de acierto, 91.32% de sensibilidad y 84.72% de especificidad.

Para la clase Diastólico el clasificador que tuvo el peor desempeño es del tipo ANN con modelo de extracción de características Envolverte Decimada; obtuvo 93.5% de tasa de acierto, 95.52% de sensibilidad y 94.07% de especificidad.

Capitulo 5

Conclusiones

- El modelo de extracción de características basado en la envolvente decimada propone un sistema sencillo y de fácil implementación, sin embargo los parámetros de rendimiento son aceptables en comparación al basado en HOG o Wavelets. Se puede lograr una compensación utilizando clasificadores del tipo SVM.
- El descriptor HOG propone un modelo de extracción de características bastante robusto, en algunos experimentos se realizó el cálculo para imágenes escaladas a un 30% encontrando que el error de clasificación se mantenía. Estos experimentos se desarrollaron paralelamente al presente trabajo y pueden ser de gran interés para investigadores en esta rama del conocimiento.
- El modelo de extracción de características basado en Wavelets es el más eficiente y con mejores resultados en cuanto a tasa de acierto. Permite una configuración de un vector de características de pequeña dimensión reduciendo así el costo computacional del sistema clasificador.
- Herramientas de software libre como Octave y Python contienen funciones de alto nivel para el análisis y tratamiento de señales.
- El modelo de extracción de características basado en Wavelets es el más eficiente y con mejores resultados en cuanto a tasa de acierto. Permite una

configuración de un vector de características de pequeña dimensión reduciendo así el costo computacional del sistema clasificador.

- Es posible desarrollar sistemas de clasificación automática que puedan ayudar en la mejora del servicio de salud donde los profesionales del área no están disponibles. Es muy importante resaltar que se puede hacer uso de herramientas de software y hardware libre para estas implementaciones logrando un bajo costo de implementación.
- El modelo propuesto de análisis a través del mapeo de la señal en una matriz es innovador en el sentido que logra una nueva representación de la señal como imagen. Esto abre las posibilidades de almacenamiento de la información utilizando otras características como colores, escalas intermedias o capas que enriquecen el conocimiento del sonido estudiado.
- En trabajos futuros se debe poner a prueba los modelos de clasificación en hardware portable de gran difusión como lo son los teléfonos inteligentes móviles. De ahí que se debe desarrollar librerías de cálculo científico para sistemas operativos tipo Android o IOS.
- Las señales fonocardiográficas provienen de la actividad del corazón humano siendo similares para distintas personas. Sin embargo se hace necesario ampliar el estudio de extracción de características de señales provenientes de personas de distintos rangos de edades, esto con el fin de observar el comportamiento de los clasificadores en entornos donde la frecuencia cardiaca cambia o los sonidos se ven afectados por más de una patología.
- El desarrollo de un fonendoscopio electrónico de bajo costo para teléfonos móviles con clasificación automática es un reto que se debe asumir; a través de él se puede mejorar la calidad de vida de muchas personas con bajos recursos económicos o pertenecientes a las poblaciones más alejadas y vulnerables logrando un diagnóstico a tiempo que no termine en afecciones mayores o más complicadas.

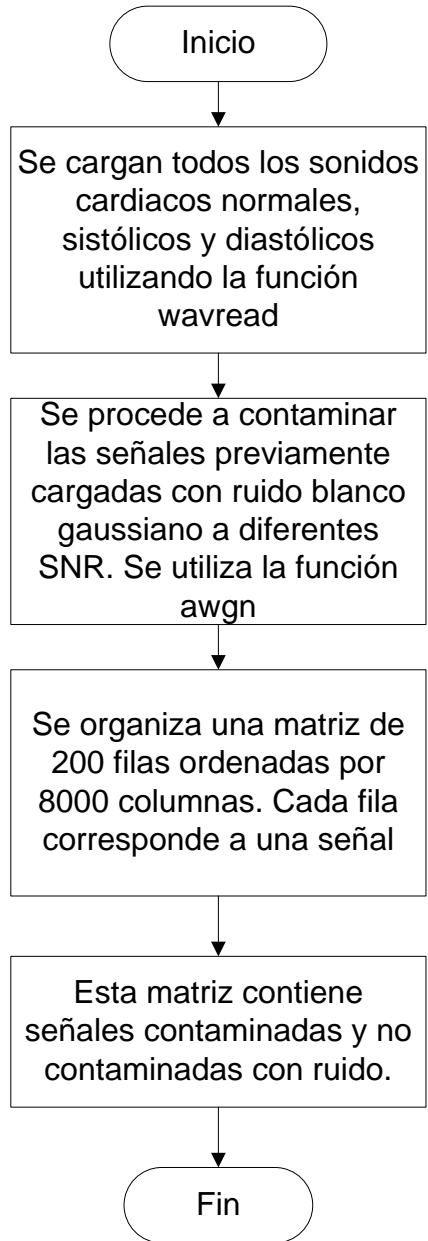
Bibliografía

- Alexander M. Mood, F. A. (2001). *Introduction to the Theory of Statistics*. New Delhi: McGraw-Hill.
- Bishop C. (1997). *Pattern Recognition and Machine Learning*. New York: Springer.
- Dalal N and Triggs B. (2005). Histograms of Oriented Gradients for Human Detection. *IEEE Computer Society Conference*, 886-893.
- Derryberry, D. (2014). *Basic Data Analysis for Time Series with R*. Somerset: John Wiley & Sons, Incorporated,.
- Feldman, M. (2005). Time-varying and non-linear dynamical system identification using the Hilbert Transform. *ASME 2005 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*, 24-28.
- Giúdice, L. D. (2009). *Anatomía cardíaca y funcionamiento del corazón*. Córdoba: El Cid Editor.
- Gonzales Caamaño, A. (2015). Significación clínica de los ruidos cardíacos. *Estudio de la hipertensión arterial*, 1-13.
- Hugo Alberto Cruz Ortega, F. X. (2016). El corazón y sus ruidos cardíacos y agregados. *Revista de la Facultad de Medicina de la UNAM*, 49-55.
- Institute, T. H. (Agosto de 2016). *Heart Information Center*. Obtenido de Anatomía del Corazón: http://www.texasheart.org/HIC/Anatomy_Esp/anato_sp.cfm
- Lakes R, M. D. (1998). *Neuronal Networks: Basics and Applications*. Berling: Springer.
- Mohri, M. (2014). *Foundations of Machine Learning*. Cambridge: MIT Press.
- NEIVA R. MACIEL, R. A. (2006). Valvuloplastia mitral y tricuspídea en una paciente con estenosis bivalvular. *Revista Argentina de Cardiología*, 1(1), 74-72.
- Octave, G. (07 de 11 de 2017). *GNU OCTAVE*. Obtenido de Scientific Programming Language: <https://www.gnu.org/software/octave/>

- P. Sáenz-Lechon N. Godino-LLOrente J. Osma-Ruiz V. and Gómez-Vilda P. (2006). Methodological issues in the development of automatic systems for voice pathology detection. *Biomedical Signal Processing and Control*, 120-128.
- Python Software Foundation. (07 de 11 de 2017). *Python*. Obtenido de <https://www.python.org/>
- Shawe-Taylor. J, C. (2006). *Kernel Methods for Pattern Analysis*. Cambridge: Cambridge University Press.
- Sheng Y. (1996). *The Transforms and Applications Handbook*. Ohio: CRC Press.
- Solutions, A. H. (06 de 11 de 2017). *Medline Plus*. (Biblioteca Nacional de los Estados Unidos) Recuperado el 30 de 11 de 2017, de <https://medlineplus.gov/spanish/ency/article/000178.htm>
- Stethoscopes, 3. L. (02 de 03 de 2014). *50 Heart and Lung Sounds Library*. (3M) Recuperado el 10 de 11 de 2015, de http://solutions.3mae.ae/wps/portal/3M/en_AE/3M-Littmann-EMEA/stethoscope/littmann-learning-institute/heart-lung-sounds/heart-lung-sound-library/
- Thuillard, M. (2001). *Wavelets in Soft Computing*. Singapore: World Scientific Publishing Co Pte Ltd.

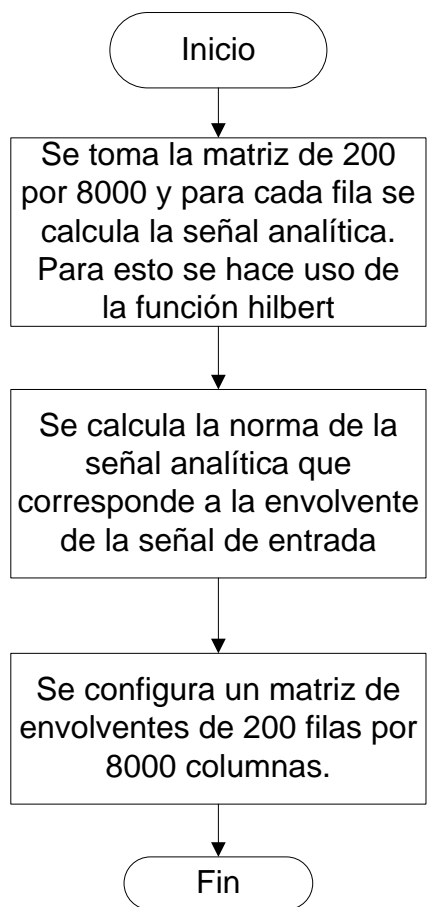
Apéndices

APÉNDICE 1. MATRIZ DE SONIDOS DE ENTRADA



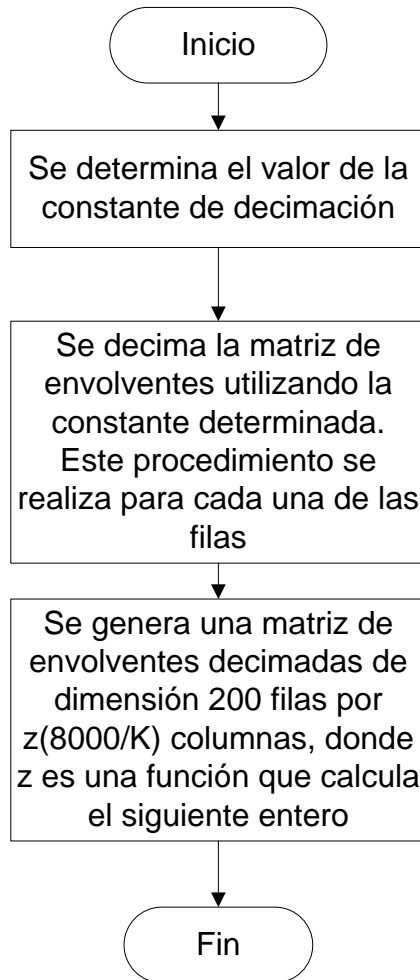
| Nombre de la función | Parámetros de Entrada | Parámetros de Salida |
|----------------------|-----------------------|--|
| wavread | (ruta) | (Vector con la señal cargada, Frecuencia de muestreo F_s) |
| awgn | (Señal, SNR) | (Señal con ruido adicionado) |
| MatrizdeEntrada | (Señales Ruidosas) | (Matriz de señales contaminada) |

APÉNDICE 2. GENERACIÓN DE MATRIZ DE ENVOLVENTES

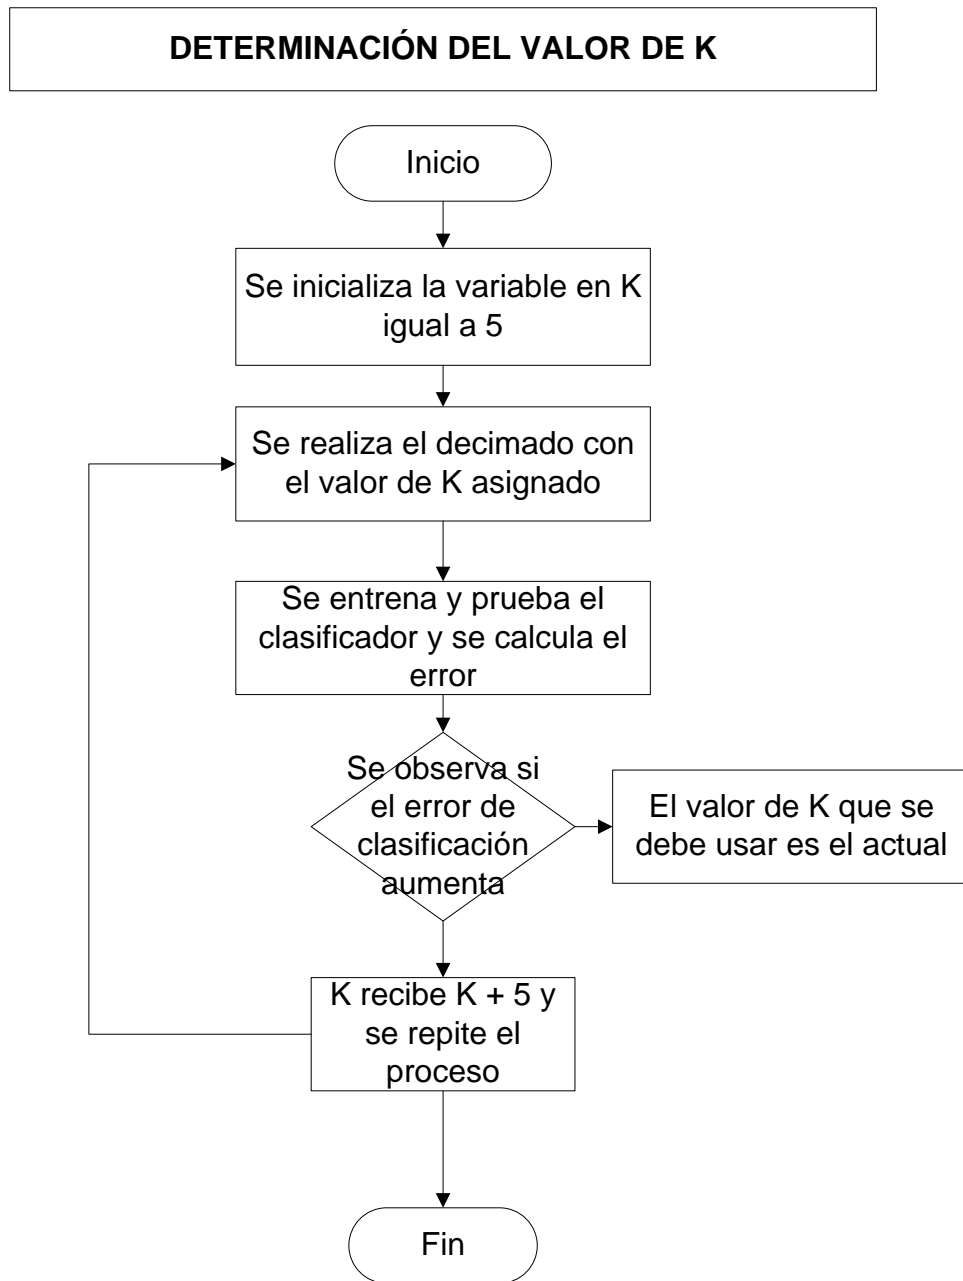


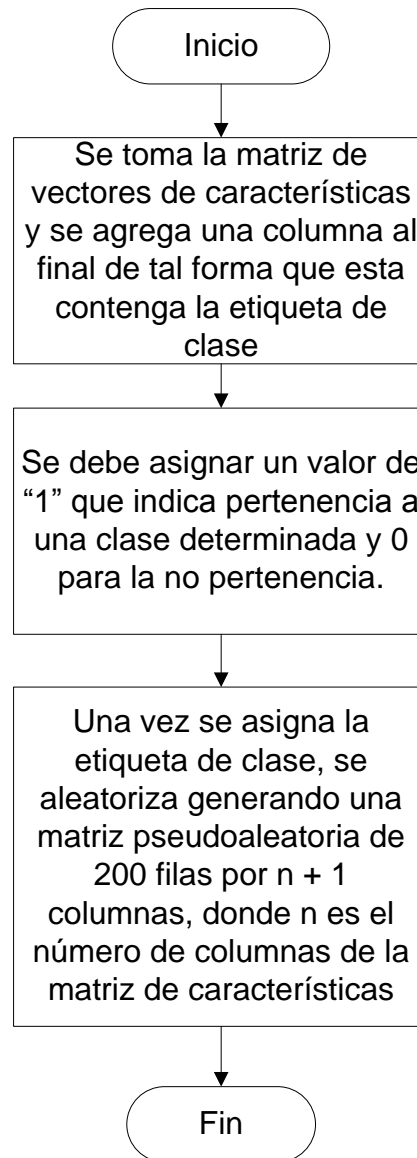
| Nombre de la función | Parámetros de Entrada | Parámetros de Salida |
|----------------------------|----------------------------------|------------------------------|
| hilbert | (Señal) | (Señal Analítica) |
| abs | (Señal compleja) | (Norma de la señal compleja) |
| ConfiguraciónDeEnvolventes | (Matriz de señales contaminadas) | (Matriz de envolventes) |

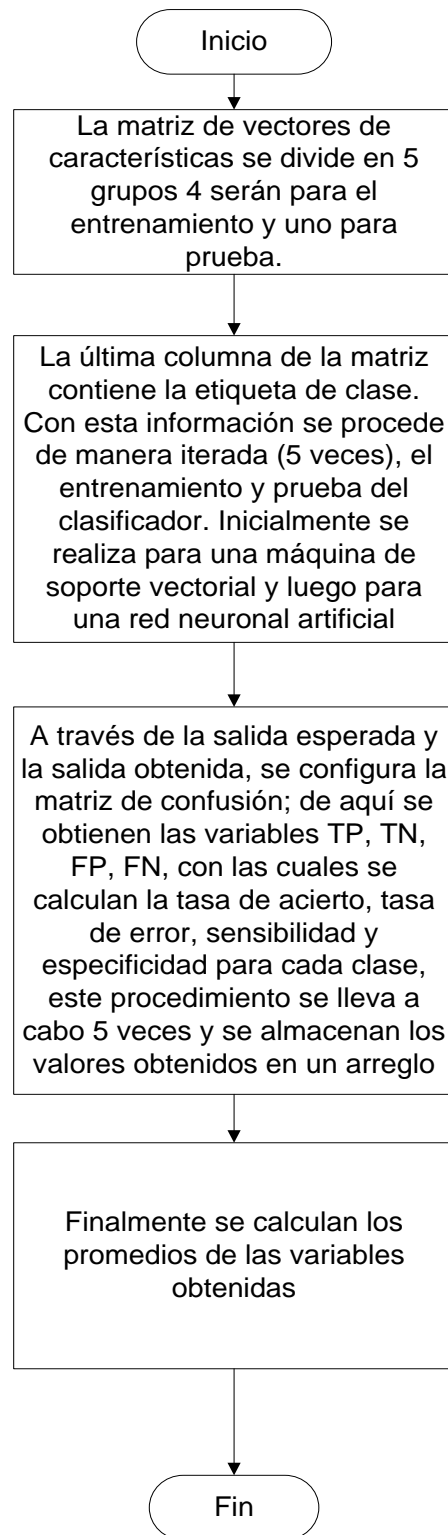
APÉNDICE 3. GENERACIÓN DE MATRIZ DE ENVOLVENTES DECIMADAS EN UN FACTOR K



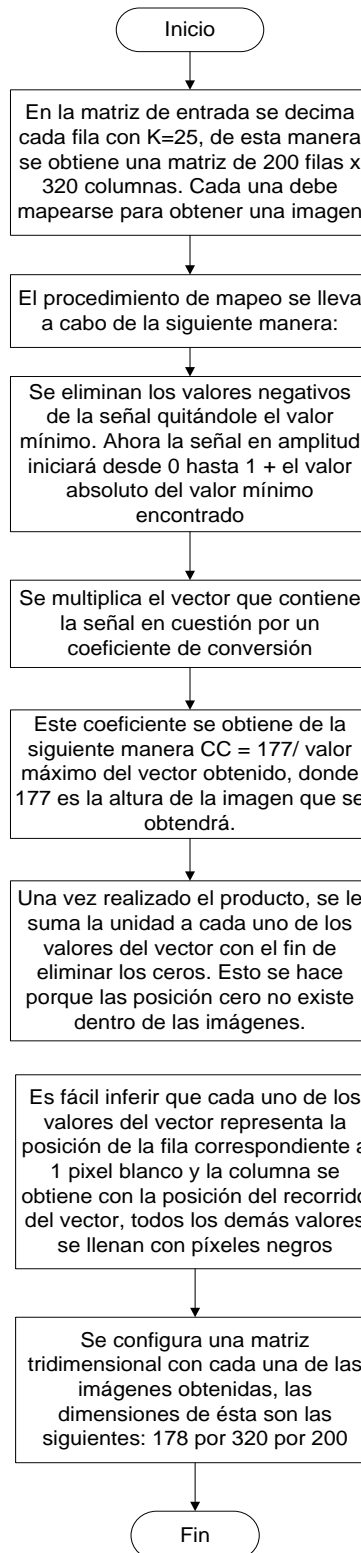
| Nombre de la función | Parámetros de Entrada | Parámetros de Salida |
|----------------------|----------------------------|-----------------------------------|
| determinaK | (Matriz de envoltentes) | K |
| generamatriz | (Matriz de envoltentes, K) | (Matriz de envoltentes decimadas) |



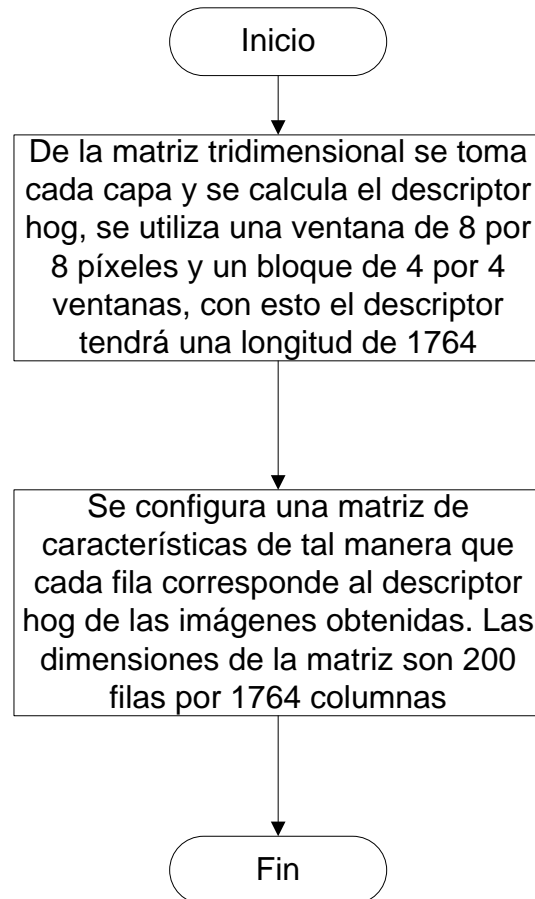
APÉNDICE 4. ASIGNACIÓN DE ETIQUETAS DE CLASE

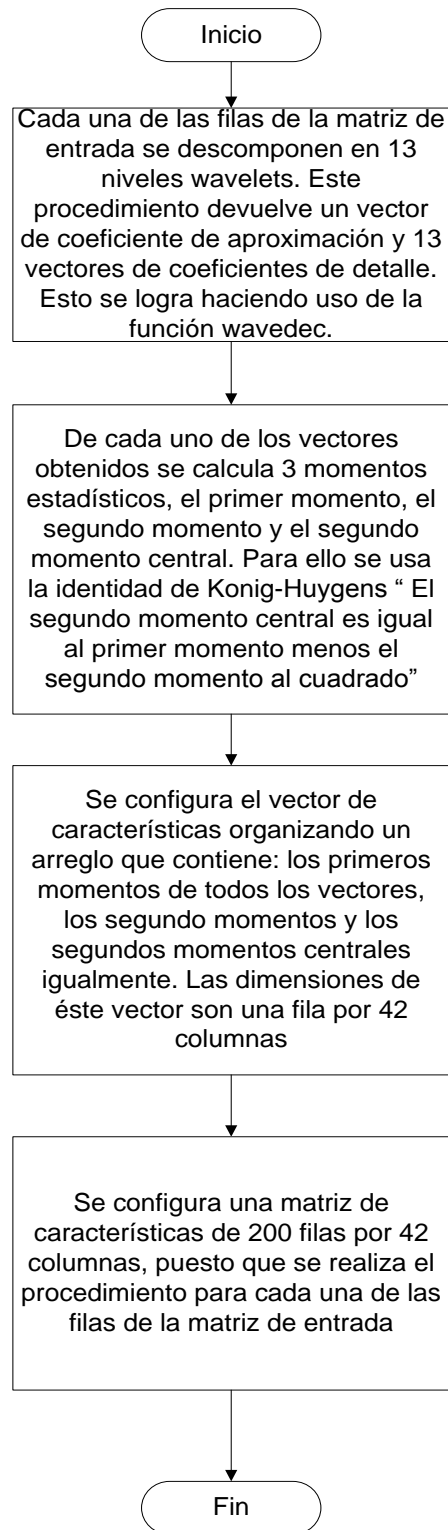
APÉNDICE 5. VALIDACIÓN 5 FOLDS

| Nombre de la función | Parámetros de Entrada | Parámetros de Salida |
|----------------------|---|------------------------------|
| svmtrain | (Objetivos, Matriz de vectores de características) | Modelo SVM |
| svmpredict | (Modelo SVM, Arreglo de etiquetas, Matriz de vectores de características) | (Etiquetas de Clasificación) |

APÉNDICE 6. MAPEO DE LAS SEÑALES DE ENTRADA

| Nombre de la función | Parámetros de Entrada | Parámetros de Salida |
|----------------------|-------------------------------------|--------------------------------------|
| devulevelImagen | Matriz de entrada, Altura, Ancho | Matriz tridimensional de imágenes |

APÉNDICE 7. CÁLCULO DEL DESCRIPTOR HOG

APÉNDICE 8. TRATAMIENTO CON WAVELETS

| Nombre de la función | Parámetros de Entrada | Parámetros de Salida |
|----------------------|--|---|
| wavedec | Señal a transformar, Frecuencia de muestreo, Nivel de descomposición | Coefficientes de aproximación y detalle, Estructura de organización |
| CalculaMomentos | Arreglos con los coeficientes de aproximación y detalle | Vector de características con los primeros, segundos y segundos momentos centrales |