



Institución Universitaria

**Algoritmos de Enjambre para la Optimización de HMM en la
Detección de Soplos Cardíacos en Señales Fonocardiográficas
Usando Representaciones Derivadas del Análisis de
Vibraciones**

Joe Alexander Jiménez Herrera

**Instituto Tecnológico Metropolitano
Facultad de Ingenierías
Medellín, Colombia
2016**

**Algoritmos de Enjambre para la Optimización de HMM en la
Detección de Soplos Cardíacos en Señales Fonocardiográficas
Usando Representaciones Derivadas del Análisis de
Vibraciones**

Joe Alexander Jiménez Herrera

Tesis o trabajo de investigación presentada(o) como requisito parcial para optar al título
de:

Magister en Automatización y Control

Director:

PhD Edilson Delgado Trejos

Codirector:

MSc Miguel Alberto Becerra Botero

Línea de Investigación:

Máquinas Inteligentes y Reconocimiento de Patrones

Grupos de Investigación:

Automática, Electrónica y Ciencias Computacionales

Calidad, Metrología y Producción

Electrónica y Automática - IUSH

Instituto Tecnológico Metropolitano

Facultad de Ingenierías

Medellín, Colombia

2016

A mi madre por su apoyo constante.

*A mi esposa y mis hijos por su paciencia,
colaboración, apoyo y comprensión.*

A todas aquellas personas que creyeron en mí.

Agradecimientos

Agradezco especialmente a mi director Edilson Delgado Trejos y a mi co-director Miguel Alberto Becerra por su colaboración, sus constantes orientaciones, su paciencia y confianza para realizar este trabajo.

A todas aquellas personas que de una u otra forma participaron de los aportes iniciales para el desarrollo de este trabajo.

Resumen

Este trabajo presenta una metodología para desarrollar un sistema automático de apoyo en la clasificación de señales fonocardiográficas (PCG). En primer lugar, las señales PCG fueron pre-procesadas. Luego descompuestas por medio de la técnica descomposición modo empírico (EMD) con algunas de sus variantes y el análisis de vibración por descomposición de Hilbert (HVD) de forma independiente, donde se comparó el costo computacional y el error en la reconstrucción de la señal original generando constructos a partir de las IMFs. A continuación, se extrajeron las características con los momentos estadísticos de los datos generados por la transformada de Hilbert-Huang (HHT), además de los coeficientes cepstrales en las frecuencias de Mel (MFCC) y cuatro de sus variantes. Por último, un subconjunto de características fue seleccionado usando conjuntos de aproximación difusos (FRS), análisis de componentes principales (PCA) y selección secuencial flotante hacia adelante (SFFS) de manera simultánea para ser utilizadas como entradas del modelo oculto de Markov (HMM) ergódico ajustado con optimización por enjambre de partículas (PSO), con el fin de proporcionar un mecanismo objetivo y preciso para mejorar la fiabilidad en la detección de soplos en el corazón, obteniendo resultados en la clasificación de alrededor del 96% con valores de sensibilidad superiores a 0.8 y de especificidad mayores a 0.9, utilizando validación cruzada (70/30 con 30 *fold*).

Palabras clave: Descomposición Modo Empírico, Ensamble de Descomposición de Modo Empírico, Completo Ensamble de Descomposición de Modo Empírico con Ruido Adaptativo, Modelos Ocultos de Markov, Coeficientes Cepstrales en las Frecuencias de Mel, Optimización por Enjambre de Partículas.

Abstract

This study presents a methodology for developing an automated support system in the classification of phonographic signals (PCG). First, the PCG signals were preprocessed. You then decomposed by the decomposition technique empirically (EMD) with some of its variants and vibration analysis by decomposition of Hilbert (HVD) independently, where the computational cost and the error was compared in the reconstruction of the original signal generating constructs from IMFs. Then the characteristics of the statistical moments data generated by the Hilbert-Huang Transform (HHT), plus cepstral coefficients at frequencies of Mel (MFCC) and four of its variants were extracted. Finally, a subset of features was selected using sets of fuzzy approximation (FRS), principal component analysis (PCA) and floating sequential forward selection (SFFS) simultaneously to be used as inputs to the hidden Markov model (HMM) ergodic adjusted particle swarm optimization (PSO), in order to provide an objective and accurate to improve reliability in detecting heart murmurs mechanism, obtaining results in the classification of about 96% with sensitivity values higher 0.8 and higher specificity to 0.9, using cross-validation (70/30 split with 30 fold).

Keywords: Empirical Mode Decomposition, Ensemble EMD, Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, Hidden Markov Model , Mel-Frequency Cepstral Coefficients, Particle Swarm Optimization.

Contenido

	Pág.
1. Capítulo 1 – Estado del Arte	6
1.1 Descomposición de señales PCG	6
1.1.1 Transformada de Fourier de Tiempo Corto (STFT)	6
1.1.2 Descomposición Modo Empírico (EMD)	7
1.1.3 Transformada Wavelet (WT)	14
1.1.4 Auto-regresivo (AR)	15
1.1.5 Análisis de Espectro Singular	16
1.1.6 Análisis de Espectro Singular Adaptativo	17
1.1.7 Análisis de Vibración por Descomposición de Hilbert (HVD)	18
1.2 Representación	19
1.2.1 Caracterización	19
1.2.2 Reducción	26
1.3 Inferencia	31
1.3.1 Clasificación	31
1.3.2 Esquemas de validación y precisión	38
2. Capítulo 2 – Marco Teórico	41
2.1 Descripción fisiológica de las señales PCG	41
2.1.1 Descripción fisiológica de las señales PCG	44
2.2 Espacios de representación	45
2.2.1 Descomposición de modo empírico (EMD)	45
2.2.2 Análisis de Vibración por Descomposición de Hilbert (HVD)	50
2.2.3 Coeficientes Cepstrales en las Frecuencias de Mel (MFCC)	52
2.2.4 Transformada de Hilbert-Huang (HHT)	53
2.3 Modelo Oculto de Markov (HMM)	54
2.4 Optimización por Enjambre de Partículas (PSO)	57
3. Capítulo 3 – Marco Experimental	59
3.1 Base de Datos	59
3.2 Metodología Propuesta	59
3.3 Pre-Procesamiento	61

3.4	Descomposición de señales	62
3.4.1	Descomposición de modo empírico (EMD).....	62
3.4.2	Descomposición rápida de modo empírico (fastEMD)	63
3.4.3	Ensamble de descomposición de modo empírico (EEMD)	64
3.4.4	Completo ensamble de descomposición de modo empírico con ruido adaptativo (CEEMDAN)	67
3.4.5	Análisis de Vibración por Descomposición de Hilbert (HVD)	69
3.5	Espacio de Representación	70
3.5.1	Coeficientes Cepstrales en la escala de Frecuencias Mel (MFCC).....	70
3.5.2	Momentos Estadísticos - Transformada de Hilbert-Huang (HHT)	74
3.6	Análisis de Relevancia	76
3.6.1	Análisis de Componentes Principales (PCA)	77
3.6.2	Fuzzy Rough Sets (FRS).....	77
3.6.3	Selección Secuencial Hacia Adelante (SFFS)	78
3.7	Entrenamiento y clasificación.....	79
3.7.1	Naive Bayes	79
3.7.2	Modelos Ocultos de Markov (HMM)	80
3.7.3	Modelos Ocultos de Markov con Aprendizaje Optimizado por PSO (PSOHMM)	80
3.8	Análisis de Datos Experimentales	81
3.8.1	Método de validación cruzada	81
3.8.2	Método de la Matriz de Confusión	81
3.8.3	Media $F\beta$	82
3.8.4	Curvas ROC.....	83
3.8.5	Diagrama de Bigotes	84
4.	Capítulo 4 – Resultados y Discusión.....	85
4.1	Espacio de Representación	87
4.2	Esquema de Clasificación de señales PCG basado en HMM	100
4.3	Esquema de Validación	102
4.4	Discusión de los resultados experimentales.....	102
5.	Conclusiones y trabajos futuros.....	103
5.1	Conclusiones	103
5.2	Trabajos futuros.....	104
A.	Anexo A: Análisis de Relevancia.....	105
6.1	Análisis de Relevancia con PCA	105
6.2	Análisis de Relevancia con FRS	110
6.3	Análisis de Relevancia con SFFS	131
B.	Anexo B: Clasificadores y Esquemas de validación.....	136

Lista de figuras

	Pág.
Figura 2-1: Señal PCG de acuerdo al tipo de soplo (Delgado, 2008).....	44
Figura 2-2: Focos de auscultación cardíaca (Delgado, 2008).....	45
Figura 3-1: Metodología propuesta.....	60
Figura 3-2: Señal PCG con normalización bipolar	61
Figura 3-3: Descomposición de la señal PCG con EMD	62
Figura 3-4: Descomposición de la señal PCG con fastEMD	63
Figura 3-5: Descomposición de la señal PCG con EEMD (basada en EMD).....	65
Figura 3-6: Descomposición de la señal PCG con EEMD (basada en fastEMD)	66
Figura 3-7: Descomposición de la señal PCG con CEEMDAN (basada en EMD)	67
Figura 3-8: Descomposición de la señal PCG con CEEMDAN (basada en fastEMD)....	68
Figura 3-9: Descomposición de la señal PCG con HVD	69
Figura 3-10: Escala de Mel y del banco de filtros triangulares aplicados	71
Figura 3-11: Ventana de Hamming y trama de la señal analizada.....	72
Figura 3-12: Solapamiento (Becerra Botero, 2013).....	73
Figura 3-13: Cálculo de los MFCC.....	74
Figura 3-14: Señal original y señal analítica	75
Figura 3-15: Descripción del Modelo Ergódico de 5 estados utilizado (Becerra Botero, 2013).....	80
Figura 3-16: Ejemplo de Diagrama de bigotes.....	84
Figura 4-1: Precisión lograda con el clasificados HMM a partir de cada sub-grupo de características utilizadas	89
Figura 4-2: Precisión lograda con el clasificados Naive Bayes a partir de cada sub-grupo de características utilizadas.....	90
Figura 4-3: Precisión lograda con el clasificados KNN a partir de cada sub-grupo de características utilizadas	90

Figura 4-4: Diagrama de frecuencia de las características que proporcionaron mejores resultados en el entrenamiento de los clasificadores	93
Figura 4-5: Gráfico de diagrama de frecuencias de las características en los análisis de relevancia	95
Figura A-1: Componentes principales de la matriz característica obtenida a partir de la técnica HVD	106
Figura A-2: Componentes principales de la matriz característica obtenida a partir de la técnica EMD	106
Figura A-3: Componentes principales de la matriz característica obtenida a partir de la técnica fastEMD	107
Figura A-4: Componentes principales de la matriz característica obtenida a partir de la técnica EEMDv1	108
Figura A-5: Componentes principales de la matriz característica obtenida a partir de la técnica EEMDv2	108
Figura A-6: Componentes principales de la matriz característica obtenida a partir de la técnica CEEMDANv1	109
Figura A-7: Componentes principales de la matriz característica obtenida a partir de la técnica CEEMDANv2	110
Figura B-1: Curva ROC clasificador HMM con matriz característica reducida a partir de PCA (normalización señal: bipolar, normalización matriz característica: unipolar).	148
Figura B-2: Curva ROC clasificador PSOHMM con matriz característica reducida a partir de PCA (normalización señal: bipolar, normalización matriz característica: unipolar)....	148
Figura B-3: Curva ROC clasificador HMM con matriz característica reducida a partir de FRS (normalización señal: bipolar, normalización matriz característica: unipolar).....	149
Figura B-4: Curva ROC clasificador PSOHMM con matriz característica reducida a partir de FRS (normalización señal: bipolar, normalización matriz característica: unipolar)....	149
Figura B-5: Curva ROC clasificador HMM con matriz característica reducida a partir de SFFS (normalización señal: bipolar, normalización matriz característica: unipolar).....	150
Figura B-6: Curva ROC clasificador PSOHMM con matriz característica reducida a partir de SFFS (normalización señal: bipolar, normalización matriz característica: unipolar)..	150
Figura B-7: Curva ROC clasificador HMM con matriz característica reducida a partir de PCA (normalización señal: unipolar, normalización matriz característica: unipolar)	151
Figura B-8: Curva ROC clasificador PSOHMM con matriz característica reducida a partir de PCA (normalización señal: unipolar, normalización matriz característica: unipolar)..	152

Figura B-9: Curva ROC clasificador HMM con matriz característica reducida a partir de FRS (normalización señal: unipolar, normalización matriz característica: unipolar).	152
Figura B-10: Curva ROC clasificador PSOHMM con matriz característica reducida con FRS (normalización señal: unipolar, normalización matriz característica: unipolar).	153
Figura B-11: Curva ROC clasificador HMM con matriz característica reducida a partir de SFFS (normalización señal: unipolar, normalización matriz característica: unipolar).	153
Figura B-12: Curva ROC clasificador PSOHMM con matriz característica reducida con SFFS (normalización señal: unipolar, normalización matriz característica: unipolar).	154
Figura B-13: Diagramas de bigotes clasificador HMM (normalización de la señal: bipolar y normalización matriz característica: unipolar reducida a partir de PCA).....	155
Figura B-14: Diagramas de bigotes clasificador PSOHMM (normalización señal: bipolar y normalización matriz característica: unipolar reducida a partir de PCA)	155
Figura B-15: Diagramas de bigotes clasificador HMM (normalización señal: bipolar y normalización matriz característica: unipolar reducida a partir de FRS)	156
Figura B-16: Diagramas de bigotes clasificador PSOHMM (normalización señal: bipolar y normalización matriz característica: unipolar reducida a partir de FRS)	156
Figura B-17: Diagramas de bigotes clasificador HMM (normalización señal: bipolar y normalización matriz característica: unipolar reducida a partir de SFFS).....	157
Figura B-18: Diagramas de bigotes clasificador PSOHMM (normalización señal: bipolar y normalización matriz característica: unipolar reducida a partir de SFFS).....	157
Figura B-19: Diagramas de bigotes clasificador HMM (normalización señal: unipolar y normalización matriz característica: unipolar reducida a partir de PCA)	158
Figura B-20: Diagramas de bigotes clasificador PSOHMM (normalización señal: unipolar y normalización matriz característica: unipolar reducida a partir de PCA).....	158
Figura B-21: Diagramas de bigotes clasificador HMM (normalización señal: unipolar y normalización matriz característica: unipolar reducida a partir de FRS).....	159
Figura B-22: Diagramas de bigotes clasificador PSOHMM (normalización señal: unipolar y normalización matriz característica: unipolar reducida a partir de FRS).....	159
Figura B-23: Diagramas de bigotes clasificador HMM (normalización señal: unipolar y normalización matriz característica: unipolar reducida a partir de SFFS).....	160
Figura B-24: Diagramas de bigotes clasificador PSOHMM (normalización señal: unipolar y normalización matriz característica: unipolar reducida a partir de SFFS).....	160

Figura B-25: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición HVD y el análisis de relevancia PCA).....	161
Figura B-26: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición HVD y el análisis de relevancia FRS).....	162
Figura B-27: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición HVD y el análisis de relevancia SFFS).....	162
Figura B-28: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EMDv3 y el análisis de relevancia PCA).....	163
Figura B-29: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EMDv3 y el análisis de relevancia FRS).....	163
Figura B-30: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EMDv3 y el análisis de relevancia SFFS).....	164
Figura B-31: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición fastEMD y el análisis de relevancia PCA).....	164
Figura B-32: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición fastEMD y el análisis de relevancia FRS).....	165
Figura B-33: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición fastEMD y el análisis de relevancia SFFS).....	165
Figura B-34: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EEMDv1 y el análisis de relevancia PCA).....	166
Figura B-35: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EEMDv1 y el análisis de relevancia FRS).....	166

Figura B-36: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EEMDv1 y el análisis de relevancia SFFS).....	167
Figura B-37: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EEMDv2 y el análisis de relevancia PCA).	167
Figura B-38: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EEMDv2 y el análisis de relevancia FRS).....	168
Figura B-39: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EEMDv2 y el análisis de relevancia SFFS).....	168
Figura B-40: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición CEEMDANv1 y el análisis de relevancia PCA).	169
Figura B-41: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición CEEMDANv1 y el análisis de relevancia FRS).....	169
Figura B-42: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición CEEMDANv1 y el análisis de relevancia SFFS).....	170
Figura B-43: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición CEEMDANv2 y el análisis de relevancia PCA).	170
Figura B-44: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición CEEMDANv2 y el análisis de relevancia FRS).....	171
Figura B-45: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición CEEMDANv2 y el análisis de relevancia SFFS).....	171
Figura B-46: Curva ROC clasificador HMM con 13 características (normalización señal: bipolar y normalización matriz característica: unipolar).....	173
Figura B-47: Curva ROC clasificador PSOHMM con 13 características (normalización señal: bipolar y normalización matriz característica: unipolar).	174

Figura B-48: Curva ROC clasificador HMM con 13 características (normalización señal: unipolar y normalización matriz característica: unipolar).	174
Figura B-49: Curva ROC clasificador PSOHMM con 13 características (normalización señal: unipolar y normalización matriz característica: unipolar).....	175
Figura B-50: Diagramas de bigotes clasificador HMM (normalización señal: bipolar y normalización matriz característica: unipolar).....	175
Figura B-51: Diagramas de bigotes clasificador PSOHMM (normalización señal: bipolar y normalización matriz característica: unipolar).....	176
Figura B-52: Diagramas de bigotes clasificador HMM (normalización señal: unipolar y normalización matriz característica: unipolar).....	176
Figura B-53: Diagramas de bigotes clasificador PSOHMM (normalización señal: unipolar y normalización matriz característica: unipolar).....	177

Lista de tablas

	Pág.
Tabla 2-1: Características de los sonidos cardíacos (Ewing, 1988)	43
Tabla 2-2: Comparación de análisis de diferentes Sonidos Cardiacos a partir de varias técnicas (H. Yao et al., 2014)	55
Tabla 3-1: Distribución de la matriz de características	73
Tabla 3-2: Estructura de la matriz de confusión utilizada	83
Tabla 4-1: Relación de tiempo de procesamiento y recursos de memoria con respecto a las técnicas de descomposición utilizadas.....	86
Tabla 4-2: Error cuadrático medio en la reconstrucción de la señal original.....	86
Tabla 4-3: Resultados de los clasificadores entrenados con los 60 coeficientes del MFCC convencional	87
Tabla 4-4: Resultados de los clasificadores entrenados con los 12 momentos estadísticos	88
Tabla 4-5: Resumen de los mejores resultados promedios, obtenidos con los clasificadores a partir de los análisis de relevancia	91
Tabla 4-6: Validación clasificadores con las características que más precisión mostraron en las pruebas iniciales	92
Tabla 4-7: Listado de índices de características agrupadas por porcentaje de ocurrencia de acuerdo a las tasas de acierto más altas.....	94
Tabla 4-8: Resumen de los mejores resultados promedios, obtenidos con los clasificadores a partir del conjunto de 25 características	94
Tabla 4-9: Listado de índices de características agrupadas por ocurrencia	96
Tabla 4-10: Resumen de los resultados promedios obtenidos con los clasificadores a partir del conjunto de 3 características (ver Tabla 4-9 umbral $2.5 \geq$)	96
Tabla 4-11: Resumen de los resultados promedios obtenidos con los clasificadores a partir del conjunto de 4 características	97

Tabla 4-12: Resumen de los resultados promedios obtenidos con los clasificadores a partir del conjunto de 5 características (ver Tabla 4-9 umbral $2.0 \geq$).....	97
Tabla 4-13: Resumen de los resultados promedios obtenidos con los clasificadores a partir del conjunto de 13 características (ver Tabla 4-9 umbral $1.5 \geq$).....	98
Tabla 4-14: Resumen de los resultados promedios obtenidos con los clasificadores a partir del conjunto de 6 características (ver Tabla 4-9, umbral $1.5 \geq$)	99
Tabla 4-15: Relación comparativa de los clasificadores con resultados más relevantes (Valores dados: Promedio \pm Desviación Estándar (Varianza)).....	101
Tabla 4-16: Precisión lograda con los clasificadores a partir del conjunto de 13 características (ver Tabla 4-9, umbral de $1.5 \geq$).....	102
Tabla A-1: Tabla de resultados de análisis de relevancia con PCA.....	105
Tabla A-2: FRS con Entropía y Entropía Difusa, sobre matriz característica con normalización bipolar	112
Tabla A-3: FRS con Neighbor, sobre matriz característica con normalización bipolar ..	113
Tabla A-4: Análisis de relevancia FRS con Neighbor Fuzzy, sobre matriz característica con normalización bipolar	120
Tabla A-5: Tabla resumen FRS, sobre matriz característica con normalización unipolar de constructos obtenidos con EMD.....	127
Tabla A-6: Relación de características obtenidas con la reducción SFFS con normalización bipolar de la señal	131
Tabla A-7: Relación de características obtenidas a partir de la reducción SFFS con normalización unipolar de la señal	132
Tabla A-8: Relación de características obtenidas a partir de la reducción SFFS	133
Tabla A-9: Relación de características obtenidas a partir de la reducción SFFS	135
Tabla A-10: Relación de características obtenidas a partir de la reducción FRS	135
Tabla B-1: Relación comparativa en base a la precisión obtenida en la validación de los clasificadores utilizados (normalización señal: bipolar, normalización matriz característica: bipolar).....	136
Tabla B-2: Relación comparativa en base a la precisión obtenida en la validación de los clasificadores utilizados (normalización señal: bipolar, normalización matriz característica: unipolar).....	137
Tabla B-3: Relación comparativa en base a la precisión obtenida en la validación de los clasificadores utilizados (normalización señal: unipolar, normalización matriz característica: bipolar).....	138

Tabla B-4: Relación comparativa en base a la precisión obtenida en la validación de los clasificadores utilizados (normalización señal: unipolar, normalización matriz característica: unipolar).	139
Tabla B-5: Validación de resultados para el clasificador HMM en las diferentes combinaciones utilizadas de normalización de la señal y la matriz de características. ..	140
Tabla B-6: Precisión, sensibilidad y especificidad clasificador HMM (Estados: 5, Gaussianas: 16).	142
Tabla B-7: Precisión, sensibilidad y especificidad clasificador PSOHMM (Estados: 5, Gaussianas: 16)	143
Tabla B-8: Precisión, sensibilidad y especificidad clasificador HMM (Estados: 10, Gaussianas: 7)	145
Tabla B-9: Precisión, sensibilidad y especificidad clasificador PSOHMM (Estados: 10, Gaussianas: 7)	145
Tabla B-10: Tiempo (seg) de entrenamiento de los clasificadores implementados en la etapa experimental.	146
Tabla B-11: Precisión clasificadores entrenados con 13 características (normalización señal: bipolar y normalización matriz característica: unipolar)	172
Tabla B-12: Valores promedio de precisión de los clasificadores entrenados con 13 características (normalización señal: unipolar y normalización matriz característica: unipolar)	172
Tabla B-13: Tiempo promedio (seg) de entrenamiento de los clasificadores implementados basados en las 13 características establecidas.	172

Lista de Símbolos y abreviaturas

Abreviaturas

NOTACIÓN	SIGNIFICADO
AHS	Sonidos Cardiacos Anormales
ANN	Red Neuronal Artificial
AR	Auto-regresivo
ARMAX	Promedio Auto-regresivo de Movimiento con Entrada Externa
ASSA	Análisis de Espectro Singular Adaptativo
AUC	Área Bajo la Curva ROC
AV	Válvulas Auriculoventriculares
AWGN	Ruido Blanco Gaussiano Aditivo
BEMD	Descomposición Bivariante de Modo Empírico
BPNN	Red de Retro-propagación Neural
CAD	Enfermedad Arterial Coronaria
CC	Coefficientes Cepstrales
CEEMDAN	Completo Ensamble de Descomposición de Modo Empírico con Ruido Adaptativo
CEMD	Descomposición Compleja de Modo Empírico
CSA	Área Transversal
CVA	Accidentes Cerebro Vasculares
CVD	Enfermedades cardiovasculares
CWT	Transformada Wavelet Continua
DFT	Transformada Discreta de Fourier
DTC	Transforma Discreta del Coseno
DWT	Transformada Discreta de Wavelet
EEMD	Ensamble de Descomposición de Modo Empírico
EGM	eGeneral Medical
EM	Expectativa de Maximización
EMD	Descomposición de Modo Empírico
EMD - ADABOOST	Descomposición de Modo Empírico - Adaboost
EMD - HHT	Descomposición de Modo Empírico - Transformada de Hilbert Huang
EMD - TEO	Descomposición de Modo Empírico - Operador de Energía Teager
EMG	Electromiográficas

FASTEMD	Descomposición Rápida de Modo Empírico
FHS	Sonidos Fundamentales del Corazón
FRS	Conjuntos de Aproximación Difusos
FT	Transformada de Fourier
GA	Algoritmos Genéticos
GMM	Modelos de Mezclas Gaussianas
HHT	Transformada de Hilbert-Huang
HMM	Modelos Ocultos de Markov
HRV	Variabilidad de la Frecuencia Cardíaca
HSS	Segmentación de Sonidos Cardíacos
HVD	Análisis de Vibración por Descomposición de Hilbert
ICA - EEMD	Análisis de Componentes Independientes - Ensamble de Descomposición de Modo Empírico
IF	Frecuencia Instantánea
IMF	Función de Modo Intrínseca
KNN	K Vecino más cercano
LDA	Análisis lineal discriminante
LFBC	Banda Cepstral de Frecuencia Lineal
LPC	Coeficientes de Predicción Lineal
LVQ	Aprendizaje con Cuantificación Vectorial
MDCTC	Coeficientes de la Transformada Cosenoidal Discreta
MEMD	Descomposición Multivariante de Modo Empírico
MFC	Frecuencias Cepstrales de Mel
MFCC	Coeficientes Cepstrales en las Frecuencias de Mel
MHS	Espectro Marginal de Hilbert
MLP	Perceptrón Multicapa
NB	Naive Bayes
OEMD	Optimización Basada en EMD
PCA	Análisis de Componentes Principales
PCG	Fonocardiográficas
PLP	Predicción Lineal Perceptual
PSO	Optimización por Enjambre de Partículas
PSOHMM	Optimización de Enjambre de Partículas para el Modelo Oculto de Markov
QTFR	Representación Cuadrática Tiempo-Frecuencia
ROC	Curva Característica Operativa del Receptor
RS	Señal Respiratoria
SAA	Área de Auscultación Estándar
SBFS	Selección Secuencial Flotante hacia Atrás
SBS	Selección Secuencial hacia Atrás
SE	Entropía de Shannon
SFFS	Selección Secuencial Flotante hacia Adelante
SFS	Selección Secuencial hacia Adelante

SNR	Relación Señal a Ruido
SSA	Análisis de Espectro Singular
STFT	Transformada de Fourier de Tiempo Corto
SVD	Descomposición en Valores Singulares
SVM	Máquina de Soporte Vectorial
TDF	Distribución Tiempo-Frecuencia
TF	Tiempo-Frecuencia
TFR	Representación Tiempo-Frecuencia
TMS	Espectrograma de Media Recortada
VQ	Cuantización Vectorial
ZCPA	Cruce por cero con Amplitud de Pico
ZCR	Tasa de Cruces por Cero

Introducción

Las señales Fonocardiografías (PCG) proporcionan información acerca del comportamiento de las válvulas cardíacas, desde el sonido causado por el flujo sanguíneo entre la aurícula, los ventrículos y las arterias, lo cual permite detectar fallos cardíacos. Comúnmente, este análisis se lleva a cabo usando sólo una zona de auscultación estándar (SAA); inicialmente, aprovechando los cambios morfológicos en el PCG causadas por los soplos cardíacos, se propusieron diferentes enfoques basados en el análisis de la energía y de las características temporales (Ahlstrom et al., 2006). Sin embargo, los soplos cardíacos tienen una naturaleza no estacionaria y exhiben cambios bruscos y transitorios de frecuencia (Delgado et al., 2009; Delgado, 2008). Otros estudios han considerado la naturaleza no lineal de señales fisiológicas con el fin de mejorar la formación y etapas de clasificación (Ahlstrom et al., 2006; Ergen, Tatar, & Gulcur, 2010), pero el incremento en el tiempo de procesamiento se convierte en un gran problema para aplicaciones en tiempo real. Por otra parte, se han propuesto varios enfoques basados en wavelets teniendo en cuenta las perturbaciones de tiempo-frecuencia asociados con soplos cardíacos (Ergen et al., 2010).

Justificación

La Organización Mundial de la Salud clasifica a las enfermedades cardiovasculares (CVD) como la principal causa de muerte en todo el mundo, afectando por igual a ambos sexos (Salud, 2013). En Europa, a pesar de que la mortalidad por CVD ha disminuido considerablemente en las últimas décadas, en muchos países europeos, se estima que el 80% de toda la mortalidad por CVD es producida en países de ingresos bajos y medios (Perk et al., 2012).

Las CVD se deben a trastornos del corazón y los vasos sanguíneos, entre ellos las cardiopatías coronarias (ataques cardíacos), las enfermedades cerebrovasculares

(apoplejía), el aumento de la tensión arterial (hipertensión), las vasculopatías periféricas, las cardiopatías reumáticas, las cardiopatías congénitas y la insuficiencia cardiaca. Las principales causas de enfermedad vascular son el consumo de tabaco, la falta de actividad física y una alimentación poco saludable (Salud, 2013). La mayoría de las CVD pueden prevenirse actuando sobre los factores de riesgo, como el consumo de tabaco, las dietas malsanas y la obesidad, la inactividad física, la hipertensión arterial, la diabetes o el aumento de los lípidos. Los ataques al corazón y los accidentes vasculares cerebrales (CVA) suelen ser fenómenos agudos que se deben sobre todo a obstrucciones que impiden que la sangre fluya hacia el corazón o el cerebro. La causa más frecuente es la formación de depósitos de grasa en las paredes de los vasos sanguíneos que irrigan el corazón o el cerebro, los CVA también pueden deberse a hemorragias de los vasos cerebrales o coágulos de sangre (Salud, 2013).

En 2008, murieron por esta causa 17.3 millones de personas, lo cual representa un 30% de todas las muertes registradas en el mundo, 7.3 millones de esas muertes se debieron a la cardiopatía coronaria y 6.2 millones a los CVA. En el 2013, 9.4 millones y medio de muertes, es decir, el 16,5% de las muertes anuales, son atribuibles a la hipertensión; incluyendo el 51% de las muertes por CVA y el 45% de las muertes por cardiopatía coronaria. Se calcula que en 2030 morirán cerca de 23,3 millones de personas por CVD, sobre todo por cardiopatías y CVA, y se prevé que sigan siendo la principal causa de muerte (Salud, 2013).

A diferencia de métodos como la ecocardiografía de alto costo y uso limitado en instituciones hospitalarias de tercer nivel y profesionales en cardiología. La auscultación es una técnica de diagnóstico cardíaco no invasiva de fácil uso y bajo costo, mediante la cual se escuchan los sonidos cardíacos y de otros órganos internos, proporcionando información importante relativa a la condición de estos órganos, para su diagnóstico y tratamiento (Sakamoto, Kusukawa, Maccanon, Luisada, & Harvey, 1965). Esta técnica es considerada útil para evaluar el funcionamiento del corazón, pero es poco confiable debido a la dificultad en la interpretación de las señales adquiridas, pues depende del buen oído y experticia del médico, lo que conlleva a no remitir al paciente cuando es requerido, o a realizar exámenes de alto costo sin que lo requiera (Delgado et al., 2009).

El desarrollo de una herramienta de apoyo diagnóstico para la detección de soplos cardíacos asequible, confiable y segura; a partir del análisis de señales PCG, que permita brindar a los pacientes un diagnóstico más acertado y rápido, generando un impacto significativo en el servicio médico, disminuyendo la subjetividad en el diagnóstico y la dependencia de la experticia del médico, lo que llevará a detecciones tempranas de afecciones cardíacas y por ende, a una disminución de las tasas de morbilidad y mortalidad.

Descripción del Problema

Actualmente los sistemas de apoyo diagnóstico en patologías cardíacas son muy costosos, razón por la cual buena parte de la población no puede acceder a los servicios de detección temprana, si no es a través de las empresas prestadoras de salud; situación que agrava la alta tasa de morbilidad y mortalidad en pacientes con patologías cardíacas que no fueron detectadas a tiempo, con cerca del 80% de las defunciones por CVD a nivel mundial (Salud, 2013).

Estos sistemas utilizan técnicas de descomposición de señales como Transformada Discreta de Fourier (DFT), Descomposición en Valores Singulares (SVD), Transformada Discreta de Wavelet (DWT), Descomposición Modo Empírico (EMD) entre otras con Coeficientes Cepstrales en las Frecuencias de Mel (MFCC) para la caracterización y Red Neuronal Artificial (ANN) para la clasificación; vislumbra la necesidad de establecer una metodología apoyada en el uso de técnicas de procesamiento dinámico, que permitan determinar de forma efectiva los parámetros iniciales de entrenamiento del clasificador y optimizar el sistema de caracterización. Permitiendo que el sistema de apoyo diagnóstico sea más rápido y preciso, logrando que el profesional de la salud pueda utilizar dicho recurso en la valoración de pacientes, ayudando a reducir efectivamente los riesgos de los mismos, con un dictamen más acertado. Obteniendo una tasa de clasificación comparable con las utilizadas convencionalmente para el soporte de diagnósticos clínicos tempranamente en pacientes con patologías cardíacas, reduciendo la tasa de mortalidad debido a soplos cardíacos.

Se han identificado dos problemas que serán abordados en esta tesis:

- La selección apropiada de los parámetros iniciales de entrenamiento del clasificador estocástico HMM, para la detección oportuna de soplos cardíacos, propiciando soportes sólidos a la evaluación clínica de sonidos cardíacos a partir de los focos de auscultación.
- La gran cantidad de procesos cíclicos y los tiempos de respuesta, derivados de la obtención de los modos de descomposición de señales multi-componentes y de su análisis para la obtención de atributos de representación.

Teniendo en cuenta lo anterior, se establece la siguiente pregunta de investigación:

¿Qué impacto en términos de desempeño, tendría sobre un sistema de apoyo diagnóstico, el mejorar la selección de los parámetros iniciales de entrenamiento del clasificador estocástico HMM y optimizar el sistema de descomposición de señales PCG con EMD o alguna de sus variantes?

Hipótesis

El uso de técnicas estocásticas integradas a la optimización con algoritmos de enjambre sobre espacios de caracterización derivados del análisis de vibraciones, permitirá la detección de soplos cardíacos, a partir de un espacio de representación abstracto dotado de alta capacidad discriminante, a fin de dar soporte a la evaluación clínica de sonidos cardíacos a partir de señales PCG de los focos de auscultación.

Objetivos de la Tesis

Objetivo General

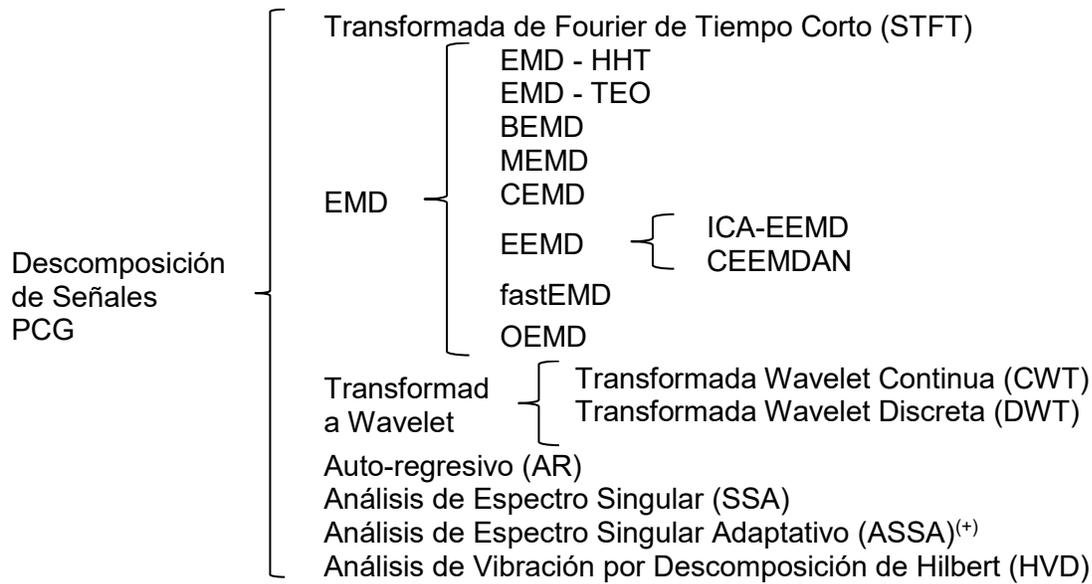
Proponer una metodología de detección de soplos cardíacos mediante modelos ocultos de Markov (HMM) continuos sobre espacios característicos derivados del análisis de vibraciones y optimizados mediante algoritmos de enjambre (PSO).

Objetivos Específicos

1. Generar un espacio de representación basado en análisis de vibraciones para realzar los soplos cardíacos sobre los sonidos funcionales del corazón.
2. Proponer un esquema de clasificación de señales fonocardiográficas basado en un modelo HMM continuo y optimizado mediante algoritmos de enjambre para su topología y aprendizaje.
3. Validar la metodología de representación y optimización mediante tasas de acierto, curvas ROC y eficiencia de procesamiento respecto a algoritmos convencionales.

Capítulo 1 – Estado del Arte

1.1 Descomposición de señales PCG



(+) Versión mejorada de la técnica

1.1.1 Transformada de Fourier de Tiempo Corto (STFT)

La transformada de Fourier de Tiempo Corto (STFT) se obtiene mediante el cálculo de la transformada de Fourier (FT) a partir de una ventana deslizante en la señal de tiempo $s(t)$, permitiendo realizar un análisis de frecuencia en diferentes intervalos de tiempo, con la representación matemática (Debbal & Bereksi-Reguig, 2008):

$$S(t, f) = \int_{-\infty}^{\infty} s(\tau)w(\tau - t)e^{-2\pi f t} d\tau \quad (1.1)$$

Donde $w(\tau - t)$ es la ventana de deslizamiento aplicada a la señal $s(t)$, t es tiempo y f es frecuencia

De hecho, la STFT no puede hacer seguimiento de los cambios repentinos en la señal en el dominio del tiempo. Para hacer frente a estos cambios de tiempo correctamente, es necesario mantener la longitud de la ventana de tiempo lo más pequeña posible, sin embargo, reducirá la resolución de frecuencia en el plano tiempo-frecuencia (TF). Por lo tanto, existe una relación entre el tiempo y las resoluciones de frecuencia (Debbal & Bereksi-Reguig, 2008), implicando una desventaja intrínseca entre la resolución de tiempo y resolución de frecuencia (Zhao, Luo, Ren, Zhang, & Shi, 2013).

1.1.2 Descomposición Modo Empírico (EMD)

La interferencia de modos “*mode mixing*”, se presenta cuando dos o más IMFs tienen frecuencias muy cercanas (aproximadamente iguales), su principal inconveniente radica en establecer apropiadamente el criterio de parada, para determinar que la señal a analizar es la residual del proceso. También se están realizando algunas variantes en el algoritmo para establecer la envolvente de la señal, ya que allí radica buena parte del costo computacional del proceso. Un estudio realizado con la finalidad de identificar movimientos utilizando señales electromiográficas (EMG) de superficie, muestra la aplicación de la HHT a los EMD de la señal para calcular diferentes momentos estadísticos (media, desviación, kurtosis y *skewness*) para caracterizar la señal; demostrando que esta técnica se ajusta adecuadamente a la no estacionariedad de la señal, permitiendo mejorar algunos resultados reportados en la literatura, donde la caracterización está basada en la Transformada Wavelet (Pinzón et al., 2009).

Algunos autores han propuesto variantes a la EMD, generando algoritmos híbridos para reducir los tiempos de procesamiento asociados principalmente al cálculo de las envolventes y las funciones que no cumplen con los criterios para ser consideradas IMF. También se han diseñado algoritmos recurrentes e iterativos basados en el EMD, para reducir el error en la reconstrucción de la señal original y mejorar la calidad de la información obtenida en el proceso de descomposición (Confarence & Sian, 2010).

- **Descomposición de Modo Empírico –Transformada de Hilbert Huang (EMD - HHT)**

Con el EMD se pueden descomponer murmullos diastólicos de forma adaptativa en un número finito de funciones IMF, luego se utiliza la transformada de Hilbert sobre las IMFs para calcular la frecuencia instantánea y amplitud instantánea, la cual ha demostrado ser una herramienta poderosa para analizar las señales no estacionarias y no lineales (Zhao et al., 2013).

La frecuencia instantánea (IF) de una señal se obtiene a partir de la primera derivada de la fase de la señal con respecto al tiempo usando la transformada de Hilbert, también se calcula en base a la distribución tiempo-frecuencia (TFD) como el primer momento condicional en la frecuencia, lo que sugiere que la frecuencia instantánea es la frecuencia media en cada momento, mientras que los términos cruzados existentes en TFD dará lugar a una rápida degradación del rendimiento y a la severa contaminación de la estimación de la frecuencia instantánea (Maragos et al., 1992). La IF del soplo diastólico se utiliza para describir los contenidos espectrales variables en el tiempo de las bandas de frecuencia característicos que son de interés para la investigación cardiovascular.

La energía local y la frecuencia instantánea derivadas de las IMFs proporcionan una resolución fina de la distribución en tiempo-frecuencia de la energía que se designa como el espectro de Hilbert, la distribución tridimensional puede reflejar la característica esencial inherente de la señal (Zhao et al., 2013).

- **Descomposición de Modo Empírico - Operador de Energía Teager (EMD - TEO)**

El algoritmo basado en el Modo Descomposición Empírica (EMD) y operador de energía Teager (TEO) se propone como un método eficaz para la estimación de la frecuencia instantánea de un soplo diastólico proporcionando a los médicos información diagnóstica y pronostica valiosa acerca de la función de las válvulas cardíacas (Zhao et al., 2013).

TEO es un operador no lineal de gran alcance y se ha utilizado con éxito en un número de aplicaciones, incluyendo el procesamiento de la señal de voz, procesamiento de imágenes, etc (Zhidong et al., 2005). TEO puede realizar un seguimiento de la energía de modulación

y estimar la amplitud instantánea y la frecuencia de las señales de AM-FM (Zhao et al., 2013). El espectro de Hilbert y el espectro marginal revelan eficazmente la de las oclusiones de las arterias coronarias que dan la base del diagnóstico de CAD (Zhao et al., 2013).

- **Descomposición Bivariante de Modo Empírico (BEMD)**

La primera extensión compleja de EMD fue propuesto por Tanaka y Mandic (2006), se emplea el concepto de señal analítica y posteriormente se aplicó el estándar EMD para analizar datos complejos / bivariante (Rehman & Mandic, 2010).

La BEMD es un algoritmo que emplea un muestreo uniforme con vectores direccionales (a lo largo de las coordenadas polares en 2D) en un círculo unitario para realizar proyecciones en múltiples direcciones, con el fin de calcular la media local de una señal de dos variables, por lo tanto no es posible la restauración de las propiedades de segundo orden de los datos de dos variables, tales como las discrepancias de poder entre los canales de datos, afectando tanto la precisión como a la complejidad computacional del algoritmo (Ahrabian et al., 2013). Debido a su estimación precisa de la media local, la BEMD ha demostrado su eficacia en el análisis de señales no estacionarias bivariadas, particularmente en aplicaciones de fusión de datos (Looney & Mandie, 2009). Usando el “*one-tailed t-test*” se estableció que el rendimiento de la BEMD con respecto al espectro marginal de Hilbert (MHS) fue significativamente mejor que la de EMD (Park et al., 2011). El proceso de tamizado se lleva a cabo de acuerdo con EMD convencional (Ahrabian et al., 2013).

Sin embargo, este método no puede garantizar un número igual de IMFs real e imaginarias, lo que limita sus aplicaciones; además las envolventes de la señal se producen mediante el uso de *splines*, donde los máximos y mínimos locales se promedian para obtener la media local de la señal de dos variables (Rehman & Mandic, 2010). La información mutua entre las partes reales y las imaginarias de la BEMD permiten una estimación más precisa de los componentes comunes a nivel del IMF (Park et al., 2011).

- **Descomposición Multivariante de Modo Empírico (MEMD)**

En el EMD de valor real, la media local se calcula por interpolación entre los máximos y mínimos locales. Sin embargo, en general, para las señales multivariantes, los máximos y mínimos locales no pueden ser definidos directamente. Por otra parte, la noción de "modos oscilatorios" que definen un IMF es bastante confuso para señales multivariantes (Rehman & Mandic, 2010).

Se ha encontrado que de manera similar al EMD, MEMD también actúa esencialmente como un banco de filtros en cada canal de la señal de entrada multivariante. Sin embargo, a diferencia de EMD, MEMD alinea mejor las correspondientes funciones del modo intrínsecas (IMF) de diferentes canales del mismo rango de frecuencia que es crucial para las aplicaciones del mundo real (ur Rehman & Mandic, 2011). También tiene la capacidad de extraer los modos rotacionales comunes a través de los componentes de la señal, lo que es adecuado, por ejemplo, para la fusión de la información de múltiples fuentes (D. P. Mandic et al., 2013).

Para hacer frente a estos problemas la MEMD, propone la adopción de las proyecciones de la señal a lo largo de diferentes direcciones en espacios n-dimensionales; estos se promedian entonces para obtener la media local, produciendo modos rotacionales n-dimensionales a través de las IMFs multivariados correspondientes. Sin embargo, la elección de un conjunto adecuado de vectores direccionales para las proyecciones de la señal en espacios n-dimensionales necesita una atención especial (Rehman & Mandic, 2010), para arrojar más luz sobre su rendimiento todavía se analiza su el comportamiento del MEMD en presencia de ruido blanco gaussiano (ur Rehman & Mandic, 2011).

- **Descomposición Compleja de Modo Empírico (CEMD)**

El complejo de EMD es una extensión del EMD adaptado para procesar señales complejas, motivado debido al gran número de aplicaciones de procesamiento de señal asociadas a señales complejas, es particularmente importante para el análisis de los procesos de fase dependiente, tales como los procedentes de sensor matrices (D. Mandic et al., 2008). La implementación del CEMD no es sencilla y dependen fundamentalmente del criterio para

encontrar los extremos locales dentro de una señal compleja, la convergencia de EMD se aborda en el marco de la teoría del punto fijo (D. Mandic et al., 2008).

Una señal compleja tiene un espectro métrico a doble cara (asimetría), por tanto, la señal compleja se puede convertir en una suma de señales analíticas a partir de una operación de filtrado sencillo que extrae los lados opuestos del espectro (Looney & Mandie, 2009), es decir que la señal compleja se descompone en un conjunto de componentes de frecuencias positivas y negativas. Debido a una dependencia mutua entre las partes real e imaginaria este proceso se aplicada simultáneamente (Amoud et al., 2008). Luego con las propiedades de las representaciones de señal en el dominio complejo (Fourier), se logra analizar solamente la parte real de dicha señal, sin pérdida de información (Tanaka & Mandic, 2007).

Sin embargo. al aplicar un EMD univariado estándar por separado para las componentes de frecuencia positivas y negativas de la señal, no se garantiza el mismo número de IMFs a través de canales de datos, lo cual es un requisito importante en aplicaciones del mundo real (Ahrabian et al., 2013). A pesar de que conserva las propiedades importantes del univariado EMD, es difícil de interpretar el significado de las IMFs extraídas y el enfoque no es adecuado para las ampliaciones de dimensiones superiores (Looney & Mandie, 2009).

- **Ensamble de Descomposición de Modo Empírico (EEMD)**

El EEMD define la verdadera componente IMF como la media de un conjunto de ensayos, cada uno consistente en la señal corrompida por ruido blanco aditivo de varianza finita. El principio de la EEMD es simple: el ruido blanco añadido rellena todo el espacio de tiempo-frecuencia de manera uniforme, lo que facilita una separación natural de las escalas de frecuencia que reduce la aparición de la mezcla de modo (D. Mandic et al., 2008).

De acuerdo con (Wu & Huang, 2009), el EEMD permite a la EMD ser un verdadero filtro diádica de los datos. Recientemente, la extracción de características basadas EEMD fue adoptada en un sistema que utiliza sonidos cardíacos grabados y señales de electrocardiograma para distinguir automáticamente entre las afecciones cardíacas

normales y anormales (Papadaniil & Hadjileontiadis, 2014). Desafortunadamente, EEMD demanda mucho tiempo de procesamiento y añade ruido a la señal original (J.-R. Huang et al., 2013). En el EEMD la componente IMF no tiene un significado físico y no se adapta de forma eficaz a la mutación característica de la señal (Xiao-feng Li et al., 2010).

- **Análisis de Componentes Independientes - Ensamble de Descomposición de Modo Empírico (ICA - EEMD)**

El algoritmo ICA-EEMD combina la ICA y el EEMD, puede obtener mejores características de la señal que el EEMD, caracteriza las mutaciones de señal con una alta precisión, por lo que el IMF tiene significado físico claro y puede restaurar con eficacia la señal de origen (Xiao-feng Li et al., 2010).

Hay dos pasos principales para lograr el proceso de análisis de componentes independientes (ICA), el primer paso es pre-procesamiento de señal mixta, incluyendo el proceso centralizado y blanqueamiento, con el fin de tratar las señales con media cero y la eliminación de la correlación entre la señal para simplificar el algoritmo y mejorar las propiedades de convergencia algoritmo. El segundo paso es el proceso de separación de fuentes, al establecer el criterio óptimo de separación de los resultados y el nivel de independencia, mediante la optimización de la función objetivo se encuentra la óptima matriz de separación para mantener los distintos componentes del vector de salida independientes entre sí tanto como sea posible, para lograr las señales de origen estimados (Xiao-feng Li et al., 2010).

- **Completo Ensamble de Descomposición de Modo Empírico con Ruido Adaptativo (CEEMDAN)**

El algoritmo CEEMDAN se basa en la descomposición modo empírico conjunto (EEMD) que se basa en la descomposición de modo empírico (EMD) permitiendo una reconstrucción exacta de la señal original y una separación espectral libre de modos (Humeau-Heurtier et al., 2014) en un menor número de iteraciones que el EEMD. Se añade ruido blanco gaussiano, en cada etapa de la descomposición, no importa cuán grande es el ruido de entrada: los resultados para CEEMDAN tienen casi la misma "forma" para diferentes tipos de ruido. Sin embargo, el rendimiento no se ve afectada por la SNR de

entrada, y el óptimo global que se alcanza alrededor del valor sugerido de 0,2 para la desviación estándar del ruido agregado (Colominas et al., 2012).

El CEEMDAN tiene la ventaja de lograr una descomposición completa sin errores en la reconstrucción y resolver el problema de diferente número de modos para diferentes realizaciones de la señal más el ruido (Torres et al., 2011), pero es necesario el ajuste del nivel de ruido añadido (Humeau-Heurtier et al., 2014). En cuanto a la amplitud del ruido añadido, Wu y Huang sugirieron utilizar pequeños valores de amplitud para datos dominados por las señales de alta frecuencia y viceversa (Wu & Huang, 2009).

- **Descomposición Rápida de Modo Empírico (fastEMD)**

La principal motivación en la búsqueda de una técnica de cálculo más rápida, se deriva del hecho de que para grandes conjuntos de datos de series de tiempo, el procedimiento de interpolación *spline* cúbica en la construcción de las envolventes puede ser una carga computacional, puesto que un sistema lineal debe ser resuelto en cada iteración (Blakely, 2005).

- **Optimización Basada en EMD (OEMD)**

La característica principal del algoritmo se basa en la construcción de la envolvente de la señal en un sentido matemático estricto, mediante la formulación y resolución de problemas de optimización convexa. Por construcción, el método no crea sub-oscilaciones, que son efectos secundarios desventajosos de los métodos tradicionales de interpolación por *spline* de Merck (B. Huang & Kunoht, 2013).

La optimización del OEMD se basa en la minimización de una suavidad cuadrática como el cuadrado de la norma de Sobolev o seminorma de n -ésimo orden, sujeta a restricciones de desigualdad puntual. El algoritmo de OEMD demanda más costo computacional que una simple interpolación, ya que es un proceso iterativo con un paso interno y otro exterior, donde en el paso exterior se identifican los puntos en los que las condiciones de desigualdad están activos, seguido de un paso interior para resolver sólo el sistema de optimización integrado por ecuaciones lineales acopladas (B. Huang & Kunoht, 2013).

1.1.3 Transformada Wavelet (WT)

El análisis WT, usando una función de base descompone progresivamente una señal en sus características de alta y baja frecuencia, es decir, coeficientes de aproximación y de detalle. En particular, Chebil y Al-Nabulsi sugirieron la transformada discreta de Wavelet (DWT) para el proceso de descomposición / reconstrucción de la señal PCG formando un esquema de HSS-DWT, donde se identifican los valores pico de S1 utilizando los coeficientes de aproximación, mientras que los valores de pico de S2 emergen de las aproximaciones reconstruidas a partir de los coeficientes de detalle (Papadaniil & Hadjileontiadis, 2014).

La Transformada Wavelet (WT) ha demostrado la capacidad de analizar el sonido del corazón con mayor precisión que otras técnicas como la STFT o la Distribución de Wigner (WD), en algunos casos patológicos (Debbal & Bereksi-Reguig, 2008).

Wavelets emplean escalas predeterminados de descomposición, expande la señal a algunas funciones base, las cuales pueden ser construidas por la dilatación, las contracciones y los cambios de una función única llamada "prototipo de onda" o "wavelet madre", actuando como microscopio en la que podemos observar diferentes partes de la señal con sólo ajustar el foco (Debbal & Bereksi-Reguig, 2008). Por tanto, es preferible descomponer la señal en sus propias fluctuaciones en lugar de filtrarla basado en valores fijos (Papadaniil & Hadjileontiadis, 2014).

- **Transformada Wavelet Continua (CWT)**

La Transformada Wavelet Continua (CWT) se utiliza para analizar señales PCG con patologías, siendo más apropiada que la Transformada Wavelet Discreta (DWT), ya estamos interesados en el análisis de señales no estacionarias y no en la codificación de señales donde DWT es más útil (Debbal & Bereksi-Reguig, 2008).

- **Transformada Wavelet Discreta (DWT)**

Proporciona una representación multi-resolución de las señales, sin embargo, no es adaptativo a la naturaleza de la señal (Zhao et al., 2013). La influencia de la elección de la madre wavelet en el análisis wavelet se ha destacado, donde la EMD supera esta limitación debido a que la base utilizada en el algoritmo se genera por la misma señal analizada, a través de un procedimiento heurístico en datos. En algunas aplicaciones, como EEG división sub-banda, la auto-extracción de las IMF podría ser una limitación (D. P. Mandic et al., 2013). Además, la transformada wavelet también subyace un principio de incertidumbre (Zhao et al., 2013).

Por otra parte, algunos investigadores, están desarrollando mejoras en el algoritmo del EMD que hacen que estos instrumentos sean muy útiles y de gran alcance para el control indirecto (D. P. Mandic et al., 2013). Y en particular, estas técnicas se pueden usar en pequeños dispositivos implantables para la vigilancia del sueño y muchas otras aplicaciones (D. P. Mandic et al., 2013).

1.1.4 Auto-regresivo (AR)

En el modelo AR cada muestra de una señal se puede expresar como una combinación lineal de muestras anteriores y una señal de error $e(n)$, donde la señal de error se supone independiente de las muestras anteriores (Akay, 1992; Liu et al., 2009). La resolución del método auto-regresivo no depende de la longitud del bloque de datos, sino más bien de orden del modelo, intervalo de muestreo, y la relación señal-ruido (SNR) relación (Kay & Marple Jr., 1981).

El modelo regresivo automático se calcula para cada ciclo de sístole y diástole de cada una de las IMFs que automáticamente se ha identificado por contener información significativa. Los parámetros del modelo de auto regresivos se calculan utilizando el método de mínimos cuadrados no restringido. Debido a sus características de rendimiento y la insensibilidad a los problemas relacionados con el sesgo de frecuencia y picos espurios (Botha, Scheffer, Lubbe, & Doubell, 2010).

1.1.5 Análisis de Espectro Singular

El análisis de espectro singular (SSA) a diferencia de algunas técnicas que ignoran por completo el solapamiento y la correlación entre los dos sonidos (Saeid Sanei et al., 2011), es una poderosa técnica de análisis de series temporales y procesamiento de señales introducida y aplicada a muchos problemas prácticos, adaptada a los cambios en las propiedades estadísticas de los datos y utilizada con eficacia para la detección de soplos en señales PCG de un solo canal (Saeid Sanei et al., 2011).

Contrariamente a los métodos tradicionales de análisis de series de tiempo y procesamiento de señales, el método básico SSA no es paramétrico y no requiere ninguna suposición previa acerca de los datos, descompone una serie en componentes excluyendo el componente aleatorio (ruido), debido a que las dos componentes tienen subespacios completamente disjuntos y pueden ser perfectamente separadas (Saeid Sanei et al., 2011). También se encontró que los valores atípicos tienen un impacto significativo en la reconstrucción y las previsiones de la SSA afectando la aplicabilidad y pertinencia de la SSA para resolver problemas del mundo real en el campo del pronóstico y el análisis de series de tiempo (Kalantari et al., 2016). Por otra parte, el caso multivariante ocupa una matriz de trayectoria de Hankel por bloques con características especiales en lugar de una matriz de Hankel, haciendo el problema aún más complejo (S Sanei & Hassani, 2015).

La principal característica del SSA es el filtrado de la señal de murmullo mediante la extracción sucesiva de proyecciones algebraicamente ortogonales, aprovechando las diferencias estadísticas entre ambas componentes basadas en la adecuada definición de la restricción (Saeid Sanei et al., 2011).

En la práctica, la primera componente de la señal se reconstruye a partir de los vectores y valores propios de la covarianza de la matriz de Hankel deslizando una ventana sobre los valores propios para tener el máximo de kurtosis. La técnica depende de la SSA dos opciones importantes la ventana longitud L y la r eficaz (S Sanei & Hassani, 2015), donde la señal deseada (ruido cardíaco) será la suma de las señales reconstruidas a partir de los valores propios (y sus correspondientes vectores propios) (Saeid Sanei et al., 2011).

La elección de L depende de varios criterios incluyendo la complejidad de los datos, el objetivo del análisis y en el contexto de la predicción, el horizonte de previsión. Por lo tanto,

la elección incorrecta de L haría implica una descomposición inferior y resultados inexactos de los pronósticos. Por otro lado, mediante la selección de r más pequeña que el verdadero número de valores propios, algunas partes de la señal (s) se perderán, y luego la serie reconstruida se vuelve menos exacta. Sin embargo, si se tiene r mayor que el número de valores propios, los componentes de ruido se incluirán en la serie reconstruida (S Sanei & Hassani, 2015).

1.1.6 Análisis de Espectro Singular Adaptativo

Durante el proceso de reconstrucción a diferencia de la SSA, el tamaño del subespacio se selecciona de forma adaptativa con el fin de maximizar la información con respecto a la señal de interés. Como resultado, aproximadamente todos los tipos de soplos se separan y se identifican debido a dos razones principales. En primer lugar, el algoritmo opera sobre señales de sonido de un solo canal en lugar de los varios canales. En segundo lugar, el subespacio de la señal se estima de forma automática y adaptativa sobre la base de un conocimiento a priori acerca de la señal deseada (Saeid Sanei et al., 2011).

En la actualidad, la versión más sencilla de SSA se basa en la norma de Frobenius que a veces se conoce como la L2-norma, cuyo objetivo es descomponer y filtrar una señal a través de una serie de que permite una predicción de una serie de tiempo menos ruidoso (Kalantari et al., 2016).

Una de las principales ventaja de la técnica ASSA en comparación con otra técnica como el PCA, es que se puede hacer frente a los datos no estacionarios desde segmentos desplazados de los datos apilados en la matriz de Hankel antes de la descomposición de la matriz de covarianza. Superando la calidad de los resultados en la separación de la señal normal y los murmullos incluso a través de las regiones solapadas temporalmente (denotado por los bajos valores de correlación entre las componentes separadas) y también el coste global de cálculo o de la velocidad de procesamiento, introduciendo un SSA no limitado a la selección de los subespacios para extraer la señal de soplo (Saeid Sanei et al., 2011).

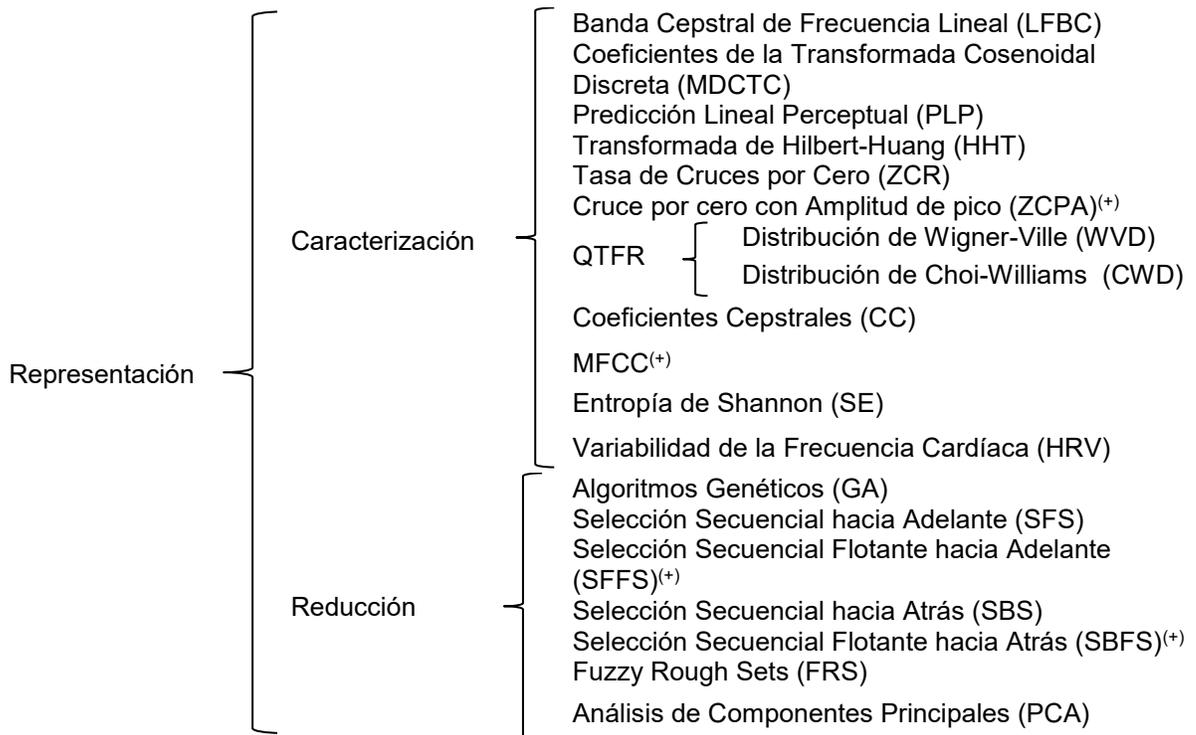
1.1.7 Análisis de Vibración por Descomposición de Hilbert (HVD)

EL HVD es una técnica basada en la transformada de Hilbert, dedicada a la descomposición de la vibración de banda ancha no estacionaria, que también permite la descomposición de las señales de múltiples componentes de banda estrecha (Feldman, 2008). El componente de banda estrecha se define como una señal con IF siempre positivo. La señal de múltiples componentes permite la extracción de un componente de banda estrecha de la composición, es decir, se puede descomponer en varias mono-componentes (Barma, Chen, Wang, Wang, & Wang, 2015), lo que resulta en la disminución de la anchura de banda del espectro de la señal restante (Feldman, 2008). Uno de los resultados más importantes de dicha técnica es la capacidad de preservar el contenido de fase de la señal mediante la construcción de cada componente en el dominio del tiempo, preservando la totalidad de las relaciones de fase (Feldman, 2011).

Los métodos de EMD y HVD aplican un algoritmo iterativo para la extracción secuencial de los componentes de acuerdo con el enfoque *sifting* (N. E. Huang et al., 1998). Estos métodos permiten la sustitución de una función compleja no estacionario por la composición de un pequeño número de funciones más simples y más adecuadas para los cálculos y los análisis (Feldman, 2008). Donde características, como la entropía, la entropía cruzada y el espectro marginal, se vuelven más representativas en el HVD que en los EMD (Barma et al., 2015). Ambos métodos son de descomposición no paramétrica y adaptativa porque tienen que ver con una señal desconocida no estacionaria a priori y no requieren de un modelo para la representación de los componentes (Feldman, 2008). El método local EMD opera con éxito con cualquier longitud de datos, mientras que el HVD requiere de registros de datos bastante largos (Feldman, 2008).

Los métodos de descomposición HT locales y globales se pueden utilizar combinadamente para identificar los componentes intrínsecos más eficazmente, pero no son eficaces para la separación de tipos de movimiento, como al azar, de impulsos, señales no oscilante (no periódicos) o señales de los sistemas lineales e invariantes en el tiempo (Feldman, 2008).

1.2 Representación



⁽⁺⁾ Versión mejorada de la técnica

1.2.1 Caracterización

▪ Banda Cepstral de Frecuencia Lineal (LFBC)

El método de extracción de características utilizando LFBC, inicia con la STDF de la señal PCG para convertir la señal de dominio temporal al dominio de la frecuencia. Después se selecciona la información asociada a la magnitud, ya que contiene la parte menos ruidosa y se rechaza la fase que generalmente incluye la interferencia de ruido. A continuación se aplica un banco de filtros o filtro pasa-bandas entre 20 y 150 Hz, para eliminar las componentes no deseadas de alta frecuencia. Luego se calcula el logaritmo de los coeficientes ya que ayuda a compensar el efecto generado por la columna de aire del estetoscopio y se utiliza la transformada discreta del coseno (DCT) reduciendo el vector de características seleccionando solo los primeros 24 coeficientes cepstrales. El siguiente paso es la eliminación de los picos de la señal, debidos al movimiento de la mano y otras actividades al momento de la adquisición de la señal PCG, aplicando un umbral de 15 dB

para atenuar el efecto del canal del estetoscopio el cual depende de la región donde se recogen los datos de la señal, por lo que es imposible neutralizar el efecto completamente. Por último, se realiza la resta de los medios cepstrales, tratando de cancelar teóricamente el efecto del canal, después de esta operación se entregan los coeficiente cepstral como un vector de características (Gautam, 2013).

- **Coefficientes de la Transformada Cosenoidal Discreta (MDCTC)**

La MDCTC o coeficientes MDCT han surgido como una herramienta dominante en la codificación de audio de alta calidad debido a la capacidad de compactación de energía similar a la DCT, además de lograr simultáneamente el muestreo crítico, la reducción del efecto de bloque y la conmutación de ventana flexible (Matsumoto et al., 1998).

El espectro MDCT de una señal es el espectro de Fourier de la señal mezclado con su alias. Esto compromete el rendimiento de la MDCT como un analizador de espectro de Fourier y conduce a posibles problemas de desajuste entre la MDCT y modelos perceptuales basadas DFT, es decir, sistemas auditivos humanos. Sin embargo, MDCT se ha aplicado con éxito a la compresión de audio perceptual sin grandes problemas si una ventana adecuada, como se emplea una ventana de seno (Matsumoto et al., 1998).

- **Predicción Lineal Perceptual (PLP)**

PLP descarta la información irrelevante del discurso y por lo tanto mejora la tasa de reconocimiento de voz (Dave, 2013). En realidad, los coeficientes reales del predictor nunca se usan en el reconocimiento, ya que típicamente muestran una alta varianza, de donde el coeficiente predictor se transforma en un conjunto más robusto de parámetros conocidos como coeficientes cepstrum.

A pesar del hecho de que el PLP se ha derivado independientemente de la técnica MFCC, hay muchas similitudes entre los dos métodos (Hönig et al., 2005), cuando no hay falta de coincidencia significativa, las características MFCC conducen a una actuación es ligeramente superior a la PLP (Hönig et al., 2005). PLP es idéntica a LPC, excepto que sus

características espectrales han sido transformadas para que coincida con las características del sistema auditivo humano (Dave, 2013).

La principal diferencia entre las técnicas de análisis LPC y PLP es que el modelo (Lineal Perceptual) LP asume la función de transferencia de todos los polos del tracto vocal con un número determinado de resonancias dentro de la banda de análisis, se aproxima a la distribución de energía igualmente bien en todas las frecuencias de la banda de análisis (Dave, 2013). Este supuesto es incompatible con la audición humana, porque más allá de 800 Hz, la resolución espectral de la audición disminuye con la frecuencia y el oído es más sensible en la gama de frecuencias medias del espectro audible (Dave, 2013).

La revisión de las diferentes etapas de procesamiento de PLP y la comparación con el cálculo MFCC motivan varias modificaciones de PLP; aunque el PLP y MFCC se derivan en el concepto de banco de filtros logarítmicamente espaciados, asociados al concepto de sistema auditivo humano y por lo tanto tenía la mejor respuesta en comparación con parámetros LPC (Dave, 2013). En particular, medimos experimentalmente cuál de los dos filtros de bancos (corteza o Mel banco de filtros) conduce a un mejor rendimiento y proponemos un banco de filtros mejorado para PLP y MFCC (Hönig et al., 2005).

- **Transformada de Hilbert-Huang (HHT)**

En 1998, el Dr. Huang Norden propuso un nuevo algoritmo de procesamiento de señales: la Hilbert Huang Transform (HHT). La Transformada de Hilbert-Huang es un poderoso método de adaptación que permite analizar los resultados de Serie el tiempo no lineales y no estacionarias (Zhao et al., 2013), para calcular la frecuencia instantánea y amplitud instantánea de la señal.

La frecuencia instantánea (IF) permite caracterizar los transitorios y los cambios rápidos en frecuencia de la señal a medida que avanza el tiempo. Donde el análisis cuantitativo de la IF de los murmullos puede ayudar al diagnóstico (Oliveira & Barroso, 2000).

- **Tasa de Cruces por Cero (ZC)**

El ZCR se define como el número de veces que la señal cruza la referencia dentro de un intervalo especificado, es decir, se utiliza para representar el número de transiciones de la señal, proporcionada por el número de veces que se cruza la línea de la actividad cero o algún otro nivel de referencia (Rangayyan, 2004).

Sin embargo, ZCR puede ser fácilmente afectada por el sesgo DC, cambio en el nivel de referencia y los ruidos de baja frecuencia. Por estas razones, sería conveniente para medir la ZCR utilizar la derivada de la señal (Rangayyan, 2004). A pesar de su simplicidad, ZCR se ha utilizado en aplicaciones prácticas, tales como el análisis de señal de voz para llevar a cabo la decisión de voz-versus-silencio y de discriminar entre sonidos sonoros y sordos (L. R. Rabiner & Schafer, 1978) y el análisis de PCG para la detección de murmullos (Rangayyan, 2004).

- **Cruce por cero con Amplitud de pico (ZCPA)**

ZCPA es un enfoque alternativo en el que la amplitud de pico entre cruces por cero adyacentes se usa como un factor de ponderación no lineal para el contenedor de frecuencia correspondiente, además usa un enmascaramiento lateral, que puede explicar su menor sensibilidad al ruido externo (Montalvão & Rodrigues Araujo, 2012).

Se propone una simple modificación del algoritmo MFCC para permitir la inclusión del efecto de enmascaramiento espectral, confirmando la superioridad de MFCC con enmascaramiento frente a otras técnicas como el ZCPA, lo cual corrobora que el enmascaramiento es un aspecto clave para mejorar la robustez en la extracción de características en presencia de ruido blanco aditivo gaussiano (AWGN) (Montalvão & Rodrigues Araujo, 2012).

- **Representación Cuadrática Tiempo-Frecuencia (QTFR)**

Son representaciones de segundo grado en el dominio tiempo-frecuencia que permiten caracterizar de forma única una señal a partir de una función subyacente llamada "*kernel*" (Papandreou-Suppappola, 2002). Estas propiedades no se limitan a satisfacer las

ecuaciones de sistemas estrictamente positivos o reales marginales y permiten reducir términos cruzados, lo que resulta en representaciones tales como la Rihaczek, Wigner-Ville (WV) y Choi-Williams (CW), entre otros (Cohen, 1995). En general, estas propiedades son elegidas porque producen representaciones visualmente atractivas o conservan cierta información de la señal original. La desventaja tradicional de utilizar cualquiera de estas representaciones de funciones para clasificadores automáticos, es la avalancha de información. Mientras que las características espectrales de una señal estacionaria produce vectores con a lo sumo unas dimensiones, una señal con longitud N potencialmente puede producir una representación con $N * (N + 1) / 2$ dimensiones linealmente independientes, por ejemplo, para una señal de 250 *mseg* muestreada a 16 *KHz*, esto equivale a no menos de 8 millones de dimensiones (Papandreou-Suppappola, 2002).

Las distribuciones Choi-Williams fueron utilizadas para describir los cambios en el contenido de frecuencia de varias señales biológicas, al igual que los sonidos producidos por los músculos (Barry & Cole, 1990) o la estructura de las señales de frecuencia cardíaca (Chan, Huang, & Lin, 2001).

Para la clasificación explícita, no es necesariamente deseable representar la distribución de energía de una señal en tiempo y frecuencia con precisión. De hecho, una representación de este tipo puede estar en conflicto con el objetivo de la clasificación, que es generar un espacio TFR que maximice la separación entre las diferentes clases, que ponen de relieve intencionalmente diferencias entre las clases (Papandreou-Suppappola, 2002). Cuando las características espectrales cambian rápidamente, es necesaria una mayor resolución en tiempo y frecuencia, y se prefieren métodos como la distribución de Wigner-Ville (Castiglioni, 2005).

Para QTFRs, no es necesario utilizar enventanado, ya que el objetivo es obtener distribuciones de energía con una representación cuadrática, distribuida en el plano del TF, sin embargo, la QTFRs a menudo supera el problema de resolución que limita la TF lineal (Papandreou-Suppappola, 2002).

- **Distribución de Wigner-Ville (WVD)**

En la distribución de Wigner-Ville, el principal inconveniente es que puede producir términos de interferencia (también llamados términos cruzados) entre los componentes de una señal de múltiples componentes, es decir, componentes adicionales en el plano tiempo-frecuencia, que a menudo enmascaran la verdadera información en tiempo-frecuencia asociada con la señal de interés, pero para reducir parcialmente los términos de interferencia, es habitual el uso de la señal analítica en lugar de la original señal (Zhao et al., 2013).

- **Distribución de Choi-Williams (CWD)**

La distribución Choi-Williams es una transformación que representa el contenido espectral de la señal no estacionaria con un mapa bidimensional de tiempo-frecuencia. La recuperación de una distribución tiempo-frecuencia representa una señal no estacionaria depende de la rapidez de los cambios en el contenido de frecuencia de la señal son. Cuando son relativamente lento, el método estándar de representación es el espectrograma, es decir, el cálculo del espectro de Fourier (ver Transformada Rápida de Fourier (FFT)) sobre una ventana de corta duración (Castiglioni, 2005).

- **Coefficientes Cepstrales (CC)**

El cepstrum se define como la transformada inversa de Fourier del espectro de Fourier de magnitud logarítmica, se utiliza para separar la función de transferencia y la señal de excitación que existe en la baja y la alta frecuencia respectivamente. Los coeficientes que componen el cepstrum resultante son conocidos como los coeficientes cepstrales (Loong, et al., 2010).

Teniendo en cuenta que la energía de la señal PCG también es una característica muy importante para el reconocimiento de patrones (Kamarulafizam et al., 2007b). Los resultados muestran que los MFCC son superiores a los CC en sistema de identificación humana basados en PCG, a pesar de los bancos de filtros lineales en el rango de frecuencia más baja, dando hasta tarifa de reconocimiento del 95% para MFCC y el 90% para CC. Otros experimentos muestran que la alta tasa de reconocimiento se debe a la aplicación de filtros de bancos y no de Mel-Escala (Loong et al., 2010).

- **Coefficientes Cepstrales en las Frecuencias de Mel (MFCC)**

Una opción popular para la extracción de características de las señales acústicas es la Coeficientes Cepstrales en las Frecuencias de Mel (MFCC) que mapea la señal en una escala no lineal que imita el oído humano. Sin embargo, la escala de Mel es casi lineal en la región de frecuencia de los sonidos del corazón y por lo tanto debe producir resultados similares con los coeficientes cepstrales estándar (CC) (Loong et al., 2010).

Muchos experimentos han demostrado que el rendimiento se puede mejorar cuando se añade la información de energía como otra característica del modelo además de cepstrums (Molau et al., 2001). La representación de los sonidos del corazón utilizando MFCC estarían a cargo de un conjunto de coeficientes cepstrum (del orden de 12 a 20 coeficientes), como resultado de una transformada de coseno del logaritmo del espectro de energía real expresado en la escala de frecuencia de Mel (Kamarulafizam et al., 2007b). Donde el coeficiente 0 puede ser considerado como una colección de las energías medias de cada uno de las bandas de frecuencia en la señal que se está analizando, razón por la cual se ignora debido a su falta de fiabilidad (Kamarulafizam et al., 2007b).

Algunos autores, proponen un método de reconocimiento de emociones basado en la voz, creando un espacio de representación a partir de la extracción de características de las IMF a base de los MFCC y de algunas variantes de este a las cuales llamaron S_MFCC, ST_MFCC, SW_MFCC y STW_MFCC; utilizando criterios de selección para las IMF a partir de operadores de energía y a la estandarización de las señales con relación a valores estadísticos obtenidos de las mismas (Xiang Li et al., 2010). Estas novedosas características surgen a partir de la obtención de una señal $S_x(t)$ que resulta de la resta de la señal de voz original y de la suma de n IMFs (n es menor o igual a 10), a la que se le aplica los MFCC para obtener los S_MFCC. De igual forma, los ST_MFCC se obtienen aplicando los MFCC a una combinación de señales de energía calculadas a partir de $S_x(t)$, mientras que los SW_MFCC resultan de calcular los MFCC a una señal $S_x(t)$ que resulta de la resta de la señal original con la suma de n IMF pero asignándole un peso diferente a cada IMF y, finalmente, los STW_MFCC surgen de una combinación de los ST_MFCC y los SW_MFCC (Xiang Li et al., 2010).

- **Entropía de Shannon (SE)**

La entropía es un valor que determina la cantidad de irregularidades en un sistema termodinámico, siendo un método ideal para medir el nivel de desorden de una señal no estacionaria (Tong et al., 2002). Un criterio basado en la entropía describe las propiedades relacionadas con la información para una representación exacta de una señal dada (Turkoglu et al., 2002). Desde el punto de vista de la teoría de la información, el concepto de entropía se generaliza como la cantidad de información almacenada en una distribución más general de la probabilidad. Shannon es el primer concepto de entropía para ser aplicado a la ciencia de la teoría de la información (Shannon, 2001).

- **Variabilidad de la Frecuencia Cardíaca (HRV)**

Las señales de variabilidad de la frecuencia cardíaca (HRV) es una propiedad intrínseca del corazón (Akhter et al., 2016), ha sido ampliamente estudiadas mediante la aplicación de medidas correspondientes a técnicas de dinámica no lineal, demostrando que los métodos tradicionales (media y desviación estándar) no son suficientes en la descripción de los cambios dinámicos de la variabilidad cardíaca (Soacha, 2005). Diferentes factores fisiológicos pueden influir en la HRV como el género, la edad, el ritmo circadiano, la respiración y la posición del cuerpo (Akhter et al., 2016).

1.2.2 Reducción

- **Algoritmos Genéticos (GA)**

GA es una técnica de búsqueda aleatoria asociada al proceso de la evolución natural de acuerdo con el concepto darwiniano de "supervivencia del más apto". Un ciclo genético consiste en tres tipos de operadores: la selección, cruce (combina los individuos seleccionados para producir mejores individuos) y mutación (intercambio del material genético dentro de los individuos, en una determinada probabilidad de mutación), donde cruce y mutación son nombrados como los operadores de recombinación (Hariharan, Polat, & Sindhu, 2014).

En GA, la información de la solución factible está codificado en un cromosoma y su aptitud es evaluada por una función objetivo. La población inicial se genera aleatoriamente y los individuos altamente entrenados son elegidos como padres para acoplarse a través de la función de selección. En el siguiente nivel, los cromosomas parentales producen los resortes fuera mediante el uso de los operadores de recombinación. Esta población se sustituye entonces a través de los cromosomas de élite (con el fin de mantener los mejores cromosomas) y el ciclo se repite para cierto número de iteraciones. Este ciclo GA termina por sí mismo al llegar al criterio de parada. Una vez completada la evolución, el mejor cromosoma en la población se toma como la solución para hacer frente el dominio del problema. Por lo tanto, GA es intrínsecamente paralelo y es beneficioso para los investigadores, ya que aumenta la velocidad de cálculo (Neoh et al., 2004). La figura 2 muestra el ciclo básico GA (Hariharan et al., 2014).

Hay ciertas especificaciones de GA que son importantes en la búsqueda de la óptima solución para el dominio del problema (Hariharan et al., 2014). La optimización de vector de características basadas en GA se emplea para incrementar la tasa de la identificación y reducir la complejidad del problema (Hariharan et al., 2014).

- **Selección Secuencial hacia Adelante (SFS)**

SFS comienza con un conjunto vacío de características y de forma iterativa selecciona una característica a la vez, empezando por la más prometedora (Gheyas & Smith, 2010) en combinación con las características seleccionadas maximiza la función de criterio (Giraldo et al., 2007). Siendo ampliamente utilizado por su sencillez y velocidad. Se han propuesto muchas variantes y aplicaciones basado en el algoritmo (Marcano-Cedeño et al., 2010).

.El objetivo principal de la función de selección es elegir un número de características del conjunto de características a partir de un conjunto de funciones vacío añadir poco a poco las funciones seleccionadas por alguna función de evaluación, que minimiza el error cuadrático medio (MSE) (Marcano-Cedeño et al., 2010). Esta rutina se detiene cuando la función de criterio no se puede maximizar con la adición de otra característica (Giraldo et al., 2007) y una vez que se añade una característica, nunca se retira (Gheyas & Smith, 2010).

- **Selección Secuencial Flotante hacia Adelante (SFFS)**

Es una versión mejorada del SFS, que en primer lugar amplía el subconjunto de características utilizando la selección hacia adelante L y luego elimina funciones mediante la selección hacia atrás R . Los valores de L y R se determinan automáticamente y se actualizan de forma dinámica, proporcionando un resultado cercano a la solución óptima (Giraldo et al., 2007), ya que ha demostrado ser adecuado para la mayoría de los conjuntos de datos del mundo real (Somol et al., 2006).

- **Selección Secuencial hacia Atrás (SBS)**

El SBS comienza con el conjunto de todas las características y elimina progresivamente las menos prometedoras (Gheyas & Smith, 2010) en cada paso hasta que el número deseado de características permanecen (Reeves & Zhe, 1999). Debido a esto, buenos predictores se pueden eliminar desde el principio en el algoritmo (en SBS, una vez que una característica se retira, se elimina de forma permanente) (Gheyas & Smith, 2010).

Sin embargo, se plantea la cuestión de si un determinado nivel de rendimiento puede garantizarse si se utiliza SBS (Reeves & Zhe, 1999). En realidad, la capacidad predictiva de un algoritmo de aprendizaje puede disminuir a medida que la dimensionalidad característica subespaciales, aumentando después de un punto máximo debido a una disminución del número de muestras para cada combinación de características, es decir, que cuando se enfrentan con los datos de alta dimensión, SBS a menudo encuentra dificultades para identificar el efecto independiente de cada variable explicativa sobre la variable de destino (Gheyas & Smith, 2010). Otra desventaja de la estrategia de SBS es que ninguna de las observaciones en el conjunto de candidatos puede ser garantizada como en el conjunto seleccionado hasta que el procedimiento de optimización se ha completado. Por lo tanto, no podemos comenzar la adquisición de datos hasta que todas las observaciones de los candidatos no deseados han sido eliminadas, inconveniente que motiva el desarrollo de una estrategia secuencial de selección hacia adelante (SFS) (Reeves & Zhe, 1999).

SBS es robusto a los problemas de interacción pero sensible a la multicolinealidad y por otro lado, SFS es robusto a problemas de multicolinealidad pero sensible para ofrecer interacción (Gheyas & Smith, 2010). Debido a que ni la SBS ni el algoritmo de SFS es óptimo, es útil saber si se puede garantizar un determinado nivel de rendimiento antes de realizar la optimización (Reeves & Zhe, 1999). Como resultado, tanto SBS y SFS pueden ser fácilmente atrapados en mínimos locales (Gheyas & Smith, 2010).

Por lo tanto, (Pudil, Novovičová, & Kittler, 1994) sugieren métodos de búsqueda flotantes (SFFS, los SFB) que realiza la búsqueda codiciosa con posibilidad de dar marcha atrás. Sin embargo, recientes estudios empíricos demuestran que la selección secuencial flota hacia adelante (SFFS) no es superior al SFS (Bensch, Schröder, Bogdan, & Rosenstiel, 2005) y la selección hacia atrás flotación secuencial (SFB) no es factible para los conjuntos de funciones de más de alrededor de 100 funciones (Ng, Goh, & Low, 1997). El problema con la adición o eliminación de opciones de forma secuencial es que la utilidad de una característica individual a menudo no es evidente por sí mismo, sino sólo en combinaciones que incluyen sólo las correctas otras características (Gheyas & Smith, 2010).

- **Selección Secuencial Flotante hacia Atrás (SBFS)**

Se consideran actualmente como herramientas de selección de características estándar, proporcionando un buen rendimiento y resultados próximos al óptimo o óptimas en la mayoría de las tareas. La definición del algoritmo hacia atrás es análogo al SFFS (Somol et al., 2006).

- **Fuzzy Rough Sets (FRS)**

El método de Conjuntos Rough (RST), inicialmente propuesta por Pawlak en 1982, es un método matemático usado en las tareas de selección de características para el tratamiento de la incertidumbre, vaguedad e imprecisión en el análisis de datos preservando la semántica de las funciones. Surge como una solución a problemas tales como la exploración de patrones ocultos, reducción de datos y análisis de relevancia, permitiendo explorar el conocimiento desde las bases de datos por medio de una matriz de

discernibilidad, que a su vez identifica como las características de un evento difieren entre si antes de la clasificación. El reconocimiento de la teoría de conjuntos rough ha sido de gran importancia para las investigaciones y desarrollo de máquinas de aprendizaje, dando lugar a varias extensiones de la teoría original y ampliando cada vez más su campo de aplicación (Jensen & Shen, 2008; Pattaraintakorn & Cercone, 2008).

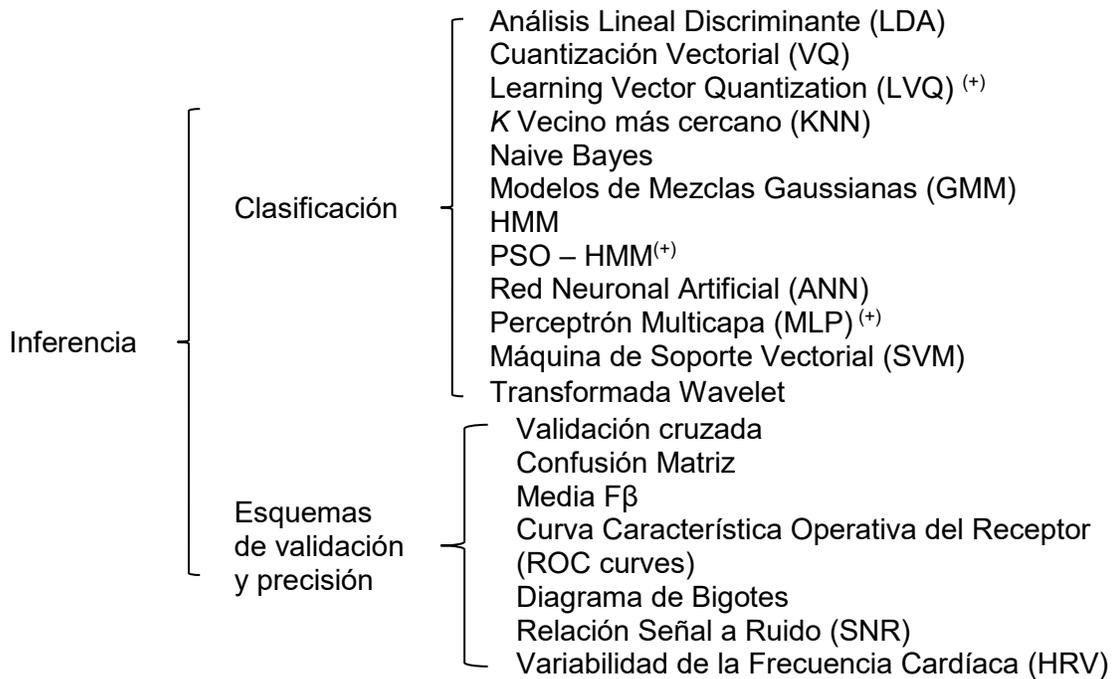
Su éxito fundamentalmente se debe a la exploración de patrones ocultos embebidos en la base de datos sin demandar información adicional, como umbrales o conocimiento de expertos. Así RST permite obtener un subconjunto denominado “*reducto*” con las características originales de mayor información. Sin embargo la aplicación de RST sólo se puede realizar sobre conjuntos de datos con valores de tipo real, por lo tanto es necesario realizar una discretización previa de los datos, generando como resultado la pérdida de información (Zadeh, 1975). La teoría de conjuntos rough, complementada con la teoría de conjuntos difusos, da lugar a un nuevo método de selección de características denominado “*Fuzzy Rough Set*” (FRS) (Y. Y. Yao, 1998) en el que ambas teorías, a pesar de relacionarse, son diferentes. Ésta técnica híbrida genera aproximaciones rough de conjuntos difusos por medio de relaciones de similaridad o particiones difusas.

- **Análisis de Componentes Principales (PCA)**

El Análisis de Componentes Principales (PCA) es probablemente la técnica estadística multi-variante más popular para el procesamiento de datos y la reducción de dimensionalidad, con una amplia gama de aplicaciones en casi en todas las disciplinas científicas (S. Huang et al., 2015).

En algunas aplicaciones de análisis de componentes principales, el número de puntos de datos es menor que la dimensionalidad del espacio de datos. Tenga en cuenta que el espacio a D-dimensiones es un conjunto de N puntos, donde $N < D$, que define un subespacio lineal cuya dimensionalidad es como máximo $N - 1$, y por lo tanto no tiene mucho sentido la aplicación de PCA para un conjunto de valores de dimensionalidad M que son mayores que $N - 1$. En efecto, si realizamos PCA nos encontraremos que al menos $(D - N + 1)$ de los valores propios son cero, correspondiente a los vectores propios a lo largo de cuyas direcciones del conjunto de datos tiene varianza cero (Bishop, 2006).

1.3 Inferencia



(+) Versión mejorada de la técnica

1.3.1 Clasificación

- **Análisis Lineal Discriminante (LDA)**

LDA logra la reducción de dimensionalidad mediante un buen vector de proyección, conservando también la mayor cantidad de información discriminatoria posible de la clase (Hariharan et al., 2014). Para lograr mejor discriminación entre las diferentes clases, el clasificador que mejor se adapte a las distribuciones de dispersión de estas clases tiene que ser utilizado (Abo-Zahhad et al., 2016).

El análisis discriminante lineal (LDA) es adoptado como un clasificador para el sistema propuesto, debido a su alto rendimiento, bajo tiempo de cálculo y a que asume que las características extraídas de cada clase tienen una distribución gaussiana multivariante con media y la misma covarianza (Abo-Zahhad et al., 2016). La decisión clasificador se lleva a cabo utilizando la regla de Bayes óptima que maximizar la probabilidad posterior o su logaritmo (Abo-Zahhad et al., 2016).

- **Cuantización Vectorial (VQ)**

La cuantización vectorial (VQ), es la generalización de la cuantización escalar, ya que en lugar de cuantizar solamente un valor escalar, ahora se hace con un vector completo, es decir, sobre un conjunto ordenado de valores reales. Además, el cambio de una a varias dimensiones, es un paso trascendental que origina y hace posibles un gran número de nuevas ideas, conceptos, técnicas y aplicaciones (Gersho & Gray, 1991). Mientras que la cuantización escalar se utiliza principalmente en la conversión analógico-digital, la cuantización vectorial se enfrenta a las sofisticadas técnicas del procesamiento digital de señales, pues por ejemplo, esta se emplea en la compresión de imágenes y de voz, pero además puede aplicarse en el reconocimiento de patrones, por lo que también se puede usar para el reconocimiento de voz (Rivera, 2012). Por lo tanto, la cuantización vectorial es mucho más que la generalización formal de la cuantización escalar (Gersho & Gray, 1991).

Parte de la complejidad del cuantizador vectorial surge de la necesidad de realizar una búsqueda, porque para poder hacer una sola identificación, se necesitan hacer tantas comparaciones como palabras existan dentro del libro código. Si su tamaño es muy grande (como por ejemplo, de más de 1024 centroides), el procedimiento puede resultar computacionalmente costoso, dependiendo de cómo se calculen las distancias (L. Rabiner & Juang, 1993).

- **Aprendizaje con Cuantificación Vectorial (LVQ)**

Es un algoritmo de aprendizaje no supervisado propuesto para generar particiones de un conjunto de vectores de datos sin etiqueta (Luengo & Herrera, 2012). El algoritmo LVQ convencional es una máquina de aprendizaje, que no requiere capas ocultas. El número de neuronas de la capa de entrada es igual a la dimensión característica del espacio, mientras que el número de neuronas de la capa de salida es igual al número de clases que forman el espacio de características. Cada neurona de la capa de entrada está conectado a todas las neuronas de la capa de salida a través de una conexión y un peso escalar está asociado con cada conexión (Homaeinezhad et al., 2011).

En el método convencional LVQ si el número de datos en las conexiones deben adaptarse a varios tipos de datos y valores atípicos probables, se puede esperar un débil desempeño. Para resolver este problema, se pueden asignar más pesos a cada conexión, aumentar el número de las neuronas de la capa de salida y teniendo en cuenta más de un nodo para cada clase. Aunque, gracias a esta modificación la precisión global de la red puede aumentar, se genera una topología incorrecta, de alta carga computacional (Homaeinezhad et al., 2011).

- ***K* Vecino más cercano (KNN)**

El KNN es la técnica que explota el concepto de agrupar los datos y la identificación de la clase particular entre los datos de gran tamaño. El sistema toma la matriz de datos disponible sobre la enfermedad como datos de entrenamiento y proporciona la salida como la enfermedad para los datos de ejemplo que se proporcionan al sistema como entrada (Roy & Misal, 2014).

Las principales ventajas del algoritmo KNN es que es robusto a datos de entrenamiento ruidoso y eficaz si el conjunto de datos de entrenamiento es grande (El-Bendary et al., 2010). Debido a su operación de naturaleza intuitiva, se utiliza KNN para generar límites de decisión lineal a tramos y por lo tanto el clasificador KNN utiliza diversas matrices de distancia para procesar los datos de entrada como la distancia: Euclídea, Chebychev, Mahalanobis y la de correlación.

El inconvenientes está en la necesidad de determinar el valor del parámetro K (número de aprendizaje de los vecinos más cercanos) y establecer el tipo de distancia a utilizar (El-Bendary et al., 2010), ya que se atribuye a esta la obtención de mejores resultados (Roy & Misal, 2014). Por otra parte, el coste de cálculo es bastante alto debido a que la distancia de cada instancia debe ser consultada para todo el entrenamiento (El-Bendary et al., 2010).

- **Naive Bayes**

Naive Bayes es la forma más simple de red bayesiana (clasificador probabilístico con entrenamiento supervisado), en el que todos los atributos son independientes (independencia condicional), dado el valor de la variable de clase. Es obvio que el supuesto de independencia condicional es rara vez cierto en la mayoría de las aplicaciones del mundo real (Zhang, 2004). El clasificador Bayesiano permite determinar la clasificación más probable para un conjunto de datos, la cual se puede obtener combinando las clasificaciones de todas las hipótesis aplicables de acuerdo a su probabilidad (Becerra Botero, 2013). Un método directo para superar la limitación de Naive Bayes es extender su estructura para representar explícitamente las dependencias entre los atributos (Zhang, 2004).

- **Modelos de Mezclas Gaussianas (GMM)**

La GMM es una poderosa herramienta estadística utilizada para la estimación de la representación de densidad de probabilidad multidimensional (Reynolds & Rose, 1995). Los parámetros del modelo se establecen en la fase de entrenamiento con el algoritmo de expectativa de maximización (EM) (McLachlan & Krishnan, 2007) o de máxima verosimilitud, los cuales tratan de obtener parámetros óptimos para el modelo, realizando un afinamiento iterativamente (Nelwamondo et al., 2005), utilizando como datos de entrada los vectores de características extraídos de sonidos del corazón (Beritelli & Spadaccini, 2011).

Hay dos diferentes metodologías para resolver el problema de la estimación de los parámetros de la mezcla gaussiana utilizando el principio de máxima probabilidad, generalmente mucho más rápido que el iterativo. El primero es un enfoque iterativo, en el que los valores de los parámetros son redefinidos por el procesamiento de los datos de forma iterativa, produciendo mejores resultados que uno recursivo (Kostantinos, 2000). En el segundo caso se estiman los coeficientes de mezcla (pesos) y, si es necesario, los primeros dos momentos de las funciones base de Gauss a partir de los datos, actualmente la Expectativa de Maximización (EM) es el algoritmo más utilizado para la estimación de parámetros (Kostantinos, 2000).

GMM contiene la función densidad de probabilidad de la observación, la cual consiste en una suma ponderada de observaciones normales, es decir, Gaussianas (con media y covarianza) que normalmente proporciona un modelo exacto de los datos (Becerra Botero, 2013).

El menor desempeño de GMM respecto a HMM, se infiere que ocurre debido a la gran dependencia de estos modelos con la estimación de los parámetros iniciales. Adicionalmente, modelar una señal con una dinámica tan fuerte como la que presenta la señal PCG, resulta complejo y más aún, cuando la señal se encuentra sin segmentar. Sin embargo, a pesar de que HMM presenta la misma dependencia, un modelo HMM Ergódico resulta mucho más adecuado para reconocer patrones secuenciales en el tiempo y para modelar señales no estacionarias continuas sin información de segmentación (Chung, 2007).

- **Modelos Ocultos de Markov (HMM)**

Los modelos ocultos de Markov, son herramientas estocásticas utilizadas para representar procesos secuenciales o densidades de probabilidad de secuencias de datos (Becerra Botero, 2013). Rabiner (1989) afirma que los HMM permiten conocer el desarrollo de procesos y procedimientos que tienen lugar siguiendo una programación probabilística.

En los sistemas de reconocimiento de patrones, la integración eficiente de la etapa de caracterización con la de clasificación, permite obtener tiempos de respuesta adecuados en la toma de decisiones. La literatura reporta un gran número de investigaciones en sistemas de reconocimiento y asistencia diagnóstica basados en HMM, donde se utilizan los coeficientes cepstrales en la escala de frecuencias Mel (MFCC) para la caracterización, logrando mejorar la interpretación de la información en la clasificación de las señales de audio y PCG (Patel & Rao, 2010).

Estos clasificadores basados en HMM presentan un alto rendimiento en la clasificación de señales PCG segmentadas por latidos, para lo cual se realiza: normalización y filtrado de la señal y cálculo de los MFCC a partir de diferentes tipos de características, como la suma de varios niveles (rangos de frecuencia) de la transformada wavelet, con los que se obtiene

una tasa de reconocimiento del 99.1%, utilizando 12 MFCC y un modelo HMM con 5 gaussianas por estado (El-Hanjouri et al., 2002).

El diseño del clasificador HMM presenta un problema cuando se realiza la estimación de la distribución de los datos de forma paramétrica, convirtiéndose en una tarea difícil, la cual requiere de la selección de la forma de distribución, que depende de la complejidad matemática de la distribución, pudiéndose presentar significativas inconsistencias, respecto a los datos reales, por lo que es requerido un método de entrenamiento del clasificador basado en un algoritmo de estimación de parámetros como los algoritmos de búsqueda ascendente que son muy dependientes de la inicialización del modelo o de los algoritmos de búsqueda global que tienen un costo computacional muy elevado (Sarria M., 2009). El algoritmo Baum-Welch se considera una generalización del algoritmo EM, el cual actualiza los pesos, de acuerdo a las secuencias observadas en el entrenamiento (Becerra Botero, 2013).

▪ PSO – HMM

PSO es un proceso de búsqueda basado en la población en que los individuos, conocidos como partículas, son soluciones candidatas para el problema de optimización a la mano abierto (Xue, Yin et al., 2006). Cada elemento de PSO como el esquema de codificación de posición de la partícula y los parámetros está diseñado específicamente en base a las características del problema antes de que el PSO se puede aplicar para resolver un problema particular (Aupetit et al., 2007).

En PSO, cada partícula representa una solución alternativa en el espacio de búsqueda multidimensional, es decir, estas partículas son vectores multidimensionales cuyas trayectorias se actualizan en base a la velocidad definida por su anterior mejor de los éxitos, *pbest*, y el mejor éxito alcanzado por la mejor de las partículas en el enjambre, *gbest*, o su vecino, *lbest* abierto (Xue et al., 2006). Las partículas cambian su estado al evolucionar en un espacio multidimensional de búsqueda hasta que el estado de equilibrio óptimo se ha alcanzado o hasta que se excedan las limitaciones de cálculo abierto (Xue et al., 2006).

Comparando los resultados de PSO-HMM con BaumWelch, muestra que el enfoque de la capacitación PSO-HMM logra mayores probabilidades de registro promedio y la reducción de errores de reconocimiento de 1.82% en el conjunto abierto (Xue et al., 2006).

- **Red Neuronal Artificial (ANN)**

La ANN es un modelo matemático- heurística con un número de capas de procesamiento altamente interconectadas inspirados por el en el funcionamiento del cerebro humano, proporcionando capacidades de aprendizaje basado en sus propensiones naturales en el almacenamiento y el uso recursivo del conocimiento experimental (Babaei & Geranmayeh, 2009). En virtud de su distribución paralela, la ANN es generalmente robusta, tolerante con los fallos y el ruido, capaz de generalizar bien y capaz de resolver problemas no lineales (Gupta et al., 2007).

Al mismo tiempo, la ANN aprende a asociar un patrón de entrada dado con un patrón de salida determinado, basándose en característica común a todos los patrones de entrada y producir el valor de salida. Estableciendo que el éxito de la ANN en la clasificación de los patrones normales y anormales del corazón, implica la optimización de la estructura de la red y los parámetros, así como el uso de una arquitectura diferente a la ANN puede mejorar la precisión de la identificación (Sinha et al., 2007).

- **Perceptrón Multicapa (MLP)**

Un Perceptrón Multicapa es un modelo clásico que consiste en varias capas de unidades de computación o neuronas, donde cada neurona en una capa ha dirigido conexiones a las neuronas de la capa siguiente relacionadas con un peso, con una función de activación sigmoidea (Luengo & Herrera, 2012).

- **Máquina de Soporte Vectorial (SVM)**

Una máquina de soporte vectorial (SVM) construye un hiperplano o conjunto de hiperplanos en un espacio de alta dimensión (Luengo & Herrera, 2012). Una buena separación se logra por el hiperplano que tiene la distancia más grande a los puntos de

datos de entrenamiento cercanos de cualquier clase, ya que en general cuanto mayor sea el margen más bajo es el error de generalización del clasificador.

Con el fin de resolver el problema de programación cuadrática (QP) que surge de las SVM, hay muchas técnicas que dependen sobre todo en la heurística para dividir el problema en partes más pequeñas y manejables (Luengo & Herrera, 2012).

- **Transformada Wavelet**

El criterio para determinar la wavelet madre más conveniente para analizar la señal PCG, consiste en comparar las energías normalizadas de los coeficientes de detalle que se obtienen a partir de un conjunto de wavelets convencionales: Daubechies, Meyer y Morlet (Soacha, 2005).

La transformada wavelet está diseñada para proporcionar una buena resolución en el tiempo y poca resolución en frecuencia cuando se analizan altas frecuencias, así como una buena resolución en frecuencia cuando se analizan bajas frecuencias (Soacha, 2005).

1.3.2 Esquemas de validación y precisión

- **Validación cruzada**

El método de validación cruzada o “*randomize bootstrap*” es un método estadístico que se vale de un conjunto de datos, los cuales son divididos en dos subconjuntos, uno para el entrenamiento y otro para la validación del modelo de clasificación (Chernick, Murthy, & Nealy, 1985).

Otra variante del método conocida como validación cruzada múltiple (*leave-one-out*) consiste en generar un conjunto con $N-1$ muestras para el entrenamiento, dejando una muestra para la validación y repitiendo dicho proceso N veces (Wong, 2015).

- **Confusión Matriz**

La matriz de confusión (matriz de rendimiento semi-global o matriz de error), permite realizar un análisis coherente del comportamiento del clasificador, esta matriz proporciona

una representación cuantitativa del rendimiento del clasificador en términos de reconocimiento de clase (Freitas et al., 2007).

- **Media $F\beta$**

Los problemas de medición han surgido en la física, la psicología, y más recientemente, las ciencias sociales (Rijsbergen, 1979). En el caso de la medición de la efectividad de la precisión y recordar, no hay ningún sentido absoluto en el que se puede decir que un par de valores de precisión y recordar es mejor o peor que otro par o para el caso que son comparables en absoluto (Rijsbergen, 1979).

- **Curva Característica Operativa del Receptor (Curva ROC)**

Las curvas ROC (*Receiver Operating Characteristic Curve*) constituye un método estadístico que permite determinar la precisión diagnóstica de un *tests* o prueba dicotómica (una cuyos resultados se puedan interpretar directamente como positivos o negativos), siendo utilizada con tres propósitos específicos: determinar el punto de corte en el que se alcanza la sensibilidad y especificidad más alta, evaluar la capacidad discriminativa del test diagnóstico, es decir, su capacidad de diferenciar sujetos sanos versus enfermos, y comparar la capacidad discriminativa de dos o más *tests* diagnósticos que expresan sus resultados como escalas continuas (Cerdeira & Cifuentes, 2012).

- **Diagrama de Bigotes**

Es un diagrama que representa la distribución de una variable continua a partir de los parámetros estadísticos de mediana, percentiles, valores extremos (mínimo y máximo) y dispersión de los datos. Además de permitir comparar gráficamente el comportamiento de una variable en varios grupos (O. C. Ibe, 2014).

- **Relación Señal a Ruido (SNR)**

Se ha encontrado que la relación de señal a ruido (SNR) de la señal PCG es crucial en el rendimiento del sistema. Una mala SNR señal puede conducir a identificaciones erróneas

de sistólica y regiones diastólica, por lo tanto, a la extracción de características inapropiadas y finalmente a una clasificación errónea (Leung et al., 2000).

- **Harmonics to Noise Ratio (HNR)**

Existen variados desordenes en una señal de audio, a los cuales se les puede asociar la presencia de ruido aditivo en la respectiva onda acústica. Debido a esto se han creado diversos algoritmos que buscan estimar la cantidad de ruido aditivo presente en las señales acústicas (Soacha, 2005).

Capítulo 2 – Marco Teórico

Debido a la cantidad de información y variables del sistema, se requiere de la estimación de características esenciales de la señal para extraer la mayor parte de la información relevante y generar un espacio de representación para la señal. Este espacio de representación puede ser bastante complejo de obtener en el dominio del tiempo, por lo que usualmente se aplican técnicas de análisis tiempo-frecuencia, las cuales permiten obtener una mayor información de las señales (Delgado, 2008). Entre las técnicas más relacionadas en la literatura, se encuentran las medidas acústicas como los coeficientes cepstrales y medidas estadísticas calculadas a partir de los constructos generados como resultado de las técnicas de descomposición aplicadas sobre la señal original.

Uno de las técnicas de descomposición es el EMD, que permite generar nuevas señales a partir de la suma de los monocomponentes o funciones del modo intrínsecas simples (IMFs) de la señal original con la finalidad de resaltar sus componentes de interés y reducir el ruido blanco en la misma, buscando la obtención de características discriminantes, aplicando coeficientes cepstrales y diferentes medidas estadísticas a los resultado obtenidos con la transformada de Hilbert-Huang (HHT), permitiendo el acoplamiento del espacio de representación con diferentes clasificadores, entre ellos los estocásticos, los cuales son adecuados para modelar señales no estacionarias. Los parámetros de entrenamiento del modelo oculto de Markov (HMM) como el número de estados o el número de gaussianas, el número de iteraciones y los criterios de convergencia; serán establecidos a partir del algoritmo Optimización por Enjambre de Partículas (PSO).

2.1 Descripción fisiológica de las señales PCG

Se conoce como ciclo cardíaco, a la dinámica cardíaca ocurrida periódicamente en el corazón desde el inicio de un latido hasta el inicio del próximo, consta de un periodo de relajación llamado diástole, donde los ventrículos se llenan de sangre, seguido de un

periodo de contracción denominado sístole, donde la sangre es expulsada a las arterias. El fonocardiograma permite representar de forma nítida y repetida, los tiempos e intensidades relativas de los sonidos generados por la actividad mecánica del corazón (Delgado, 2008).

El corazón cuenta con cuatro cavidades: dos cavidades superiores denominadas aurículas y dos inferiores llamadas ventrículos, separadas entre sí por las válvulas auriculoventriculares (AV); las válvulas AV (Mitral y Tricúspide) impiden que de los ventrículos se regrese la sangre a las aurículas durante la sístole. Las válvulas sigmoideas (Aórtica y Pulmonar) impiden que se regrese la sangre de las arterias aorta y pulmonar a los ventrículos durante la diástole, de igual forma el ventrículo izquierdo se separa de la arteria aorta por medio de la válvula sigmoidea aórtica y la válvula sigmoidea separa el ventrículo derecho de la arteria pulmonar (Ganong, 2010).

Dos sonidos se producen normalmente cuando la sangre fluye en una sola dirección a través de las válvulas del corazón durante cada ciclo cardíaco S1 y S2. En ocasiones pueden escucharse otros dos tipos de ruidos denominados S3 y S4, los cuales son considerados como componentes anormales de sonidos cardíacos que ocurren durante el periodo diastólico y están asociados con disfunciones del miocardio (Delgado et al., 2009; Tseng, Ko, & Jaw, 2012), y no son considerados en los experimentos realizados en este trabajo.

Tres conceptos están relacionados con las señales PCG (H. Yao, Ma, & Dong, 2014):

- Los ruidos cardíacos fundamentales (FHS), incluyendo S1 y S2 son causados por el cierre repentino de las válvulas mitral y tricúspide, y el cierre de las válvulas aórtica y pulmonar, respectivamente.
- Los sonidos cardíacos anormales (AHS), incluyendo S3 y S4 (siempre inaudible) generados por el rápido llenado ventricular al comienzo de la diástole, y el llenado ventricular debido a la contracción atrial separado.
- Los soplos, divididos como soplos inocentes y murmullos nocivos, producidos por el flujo sanguíneo turbulento a través de una válvula de flujo bloqueado o hacia atrás a través de una válvula con fugas. FHS, AHS, y murmullos son indicadores importantes de las Enfermedades cardiovasculares (CVD).

El primer ruido cardíaco (S1) o sístole, es un “*lub*” poco prolongado, causado por las vibraciones creadas por el cierre repentino de la mitral y tricúspide, al contraer los ventrículos y bombear sangre hacia la aorta y la arteria pulmonar en el inicio de la ventricular sístole (Ganong, 2010; Phua, Chen, Dat, & Shue, 2007). El ruido S1 está dividido en cuatro componentes: el primero de baja frecuencia, cuando la primera contracción del miocardio en el ventrículo empuja la sangre hacia las aurículas; el segundo componente es de alta frecuencia y comienza con la tensión abrupta del cierre de las válvulas AV. El tercer componente está dado por la oscilación de la sangre entre la raíz de la aorta y las paredes ventriculares; y el cuarto componente es producido por las vibraciones debidas por la turbulencia en la expulsión de la sangre a través de la aorta y la arteria pulmonar.

El segundo sonido cardíaco denominado diástole (S2), es un corto y agudo “*dup*”, causado cuando los ventrículos finalizan la expulsión, para relajarse y dejar que las válvulas aórtica y pulmonar se cierren justo después del final de la sístole ventricular, constituyendo dos componentes de alta frecuencia. Son los sonidos “*lubb-DUPP*” que son considerados como el latido del corazón. S1 tiene una duración de alrededor de 0,15 s y una frecuencia de 25-45 Hz; por otro lado, S2 que generalmente tiene una duración menor que S1, dura alrededor 0,12 s, con una frecuencia de 50 Hz (Ganong, 2010; Phua et al., 2007).

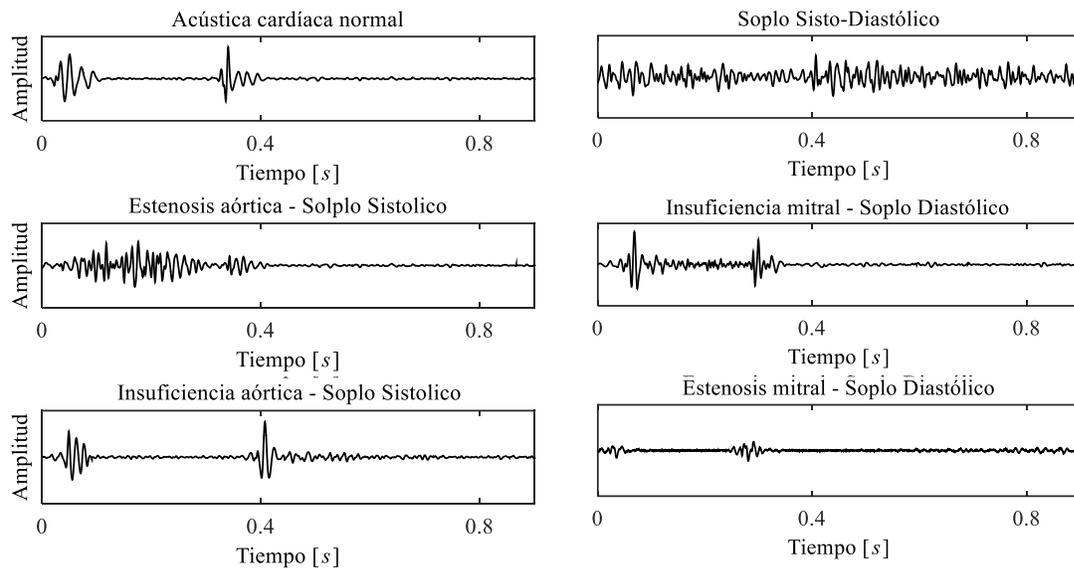
El flujo sanguíneo es laminar y por ende silencioso hasta cierta velocidad, pero cuando esta velocidad es rebasada; el flujo sanguíneo se torna turbulento, generando ruidos anormales al pasar por el corazón y los grandes vasos. Los sonidos cardíacos tienen un tiempo de duración que oscila entre los 0.04 s y los 0.12 s, con unos componentes de frecuencia dentro del rango de 20 Hz a 150 Hz, especificados de acuerdo con el sonido como se describe en la Tabla 2-1.

Tabla 2-1: Características de los sonidos cardíacos (Ewing, 1988)

Ruido	Duración (s)	Rango frecuencia (Hz)
S1	0.1 – 0.12	25 – 45
S2	0.08 – 0.14	50 – 60
S3	0.04 – 0.05	20 – 50
S4	0.04 – 0.05	< 25

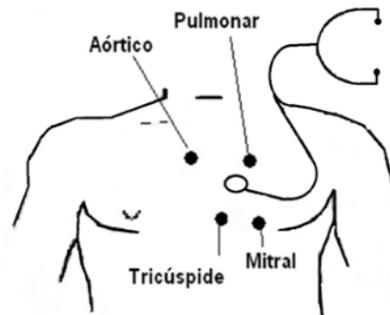
Los daños o defectos valvulares debidos a una brusca disminución en el calibre de una arteria o válvula cardíaca, ocasionan vibraciones anormales del flujo sanguíneo, generando sonidos cardiacos de alta frecuencia denominados soplos (véase Figura 2-1) relacionados con la inadecuada apertura valvular y a la regurgitación mitral o estenosis, que se presenta cuando alguna válvula no se cierra completamente, ocasionando un reflujo en sentido inverso al normal. Según la fase del ciclo cardíaco en el que se produzcan los soplos, estos pueden ser: Sistólicos, Diastólicos y Continuos los cuales ocurren durante la sístole y la diástole (Delgado, 2008).

Figura 2-1: Señal PCG de acuerdo al tipo de soplo (Delgado, 2008)



2.1.1 Descripción fisiológica de las señales PCG

La auscultación de los sonidos cardiacos se puede realizar en 4 diferentes puntos correspondientes a las cuatro válvulas del corazón denominados focos de auscultación cardíaca (Figura 2-2): aórtico, mitral, tricúspide y pulmonar, los cuales son zonas de la pared torácica en donde se puede detectar de manera clara e intensa una determinada válvula, para la búsqueda de ruidos cardiacos (Delgado, 2008).

Figura 2-2: Focos de auscultación cardíaca (Delgado, 2008)

2.2 Espacios de representación

En general, las características temporales están determinadas de forma más precisa en las señales ECG que en las PCG, ya que la información fisiológica del ECG se concentra en el eje temporal, mientras que la información contenida en el PCG está regida por parámetros de naturaleza acústica (intensidad, tono y timbre) (Delgado, 2008).

2.2.1 Descomposición de modo empírico (EMD)

El EMD es un método de análisis, que permite descomponer en forma adaptativa, señales no lineales y no estacionarias (señal multi-componente) en una suma de componentes llamadas funciones modales intrínsecas IMF (Schlotthauer, Torres, & Rufiner, 2009), las cuales son funciones base dependientes, con significado estadístico y con las que se puede discriminar el ruido de la información y determinar sus características (N. E. Huang, 2005), garantizando que los términos residuales sean funciones monótonas mediante el criterio de convergencia, determinando la tendencia de la señal sin datos a priori (Huan, Liu, & Hong, 2009). Así, una señal es expresada mediante la suma de las Funciones de Modo Intrínseco (IMFs) y su residuo (Ecuación (2.1)), lo que permite reconstruir una nueva señal, sumando n IMFs seleccionados, para una finalidad específica entre ellas: realzar características deseadas y eliminar ruido en la señal (J. Wang, Zhang, & Liu, 2008; Xin & Xiang, 2010).

$$x(t) = \sum_i^n IMF_i(t) + r(t) \quad (2.1)$$

Cada función obtenida en el proceso de descomposición debe cumplir con algunas características básicas para poder considerarse como IMF, entre las cuales podemos mencionar (ver Ecuación (2.2) y (2.3)):

$$\text{Número de Extremos} = \text{Número de Máximos} + \text{Número de Mínimos} > 1 \quad (2.2)$$

$$0 \leq \text{Número de Extremos} - \text{Número de Cruces por Cero} \leq 1 \quad (2.3)$$

EMD (Algoritmo 2-1) es una herramienta eficaz para la estimación de la Función Intrínseca (IF) de una señal limpia, pero proporciona una mala estimación en presencia de ruido blanco. Al descomponer una señal con ruido, las IMFs surgen de la fuga espectral entre modos y los bancos de filtros de comportamiento en presencia de ruido, capturando tanto el ruido como la señal en el mismo modo demostrando ser dependiente de fase. El proceso se entiende mejor considerando la señal con ruido en el plano tiempo-frecuencia, el algoritmo está operando en proyecciones en este plano, a partir de la banda de frecuencia más alta y adaptativamente se mueve hacia frecuencias más bajas, extrayendo primero ruido puro, ya que todavía no ha alcanzado la frecuencia de la señal. Estas proyecciones no son completamente ortogonales, y por lo tanto hay una cierta mezcla de frecuencia en los modos. Mientras que en la región de ruido puro, EMD se comporta como un banco de filtros, la extracción de ruido de una manera casi diádica (Kaslovsky & Meyer, 2010).

Algoritmo 2-1 EMD

Begin

α : criterio de parada

γ : tendencia

E : energía

$d(t) = x(t)$

$i = 0$

While $E(x(t)) \geq \gamma$

While $d(t) \leq \alpha$

$M_i = \text{maxlocal } x(t), m_i = \text{minlocal } x(t)$

$M(t) = \text{Interpolación } (M_i)$

$m(t) = \text{Interpolación } (m_i)$

$e(t) = \frac{[M(t) + m(t)]}{2}$

```

     $d(t) = x(t) - e(t)$ 
end while
     $IMF_i = d(t)$ 
     $x(t) = x(t) - IMF_i$ 
end while
end

```

- **Ensamble de Descomposición de Modo Empírico (EEMD)**

El EEMD (Algoritmo 2-2) se basa en el EMD, realizando varias iteraciones sobre la señal agregando ruido blanco gaussiano (*con media de la distribución: 0.0 y varianza: 1.0*) en cada iteración, para obtener un conjunto de IMFs, las cuales se promedian de acuerdo al número de iteraciones realizadas (Y.-H. Wang, Yeh, Young, Hu, & Lo, 2014); aumentando drásticamente la carga computacional, logrando consigo solucionar el problema de mezcla de modos debido a las propiedades estadísticas del ruido blanco, distribuyendo su densidad espectral de potencia de manera uniforme en todo el dominio de la frecuencia (Lin et al., 2013) y cancelando el ruido agregado en cada iteración al promediar las IMFs obtenidas en cada modo de las diferentes soluciones gracias a las características del ruido agregado.

De hecho, el EEMD ha acarreado algunos nuevos problemas, ya que la señal reconstruida incluye ruido blanco residual y las diferentes realizaciones de la señal más el ruido pueden producir diferente número de modos, lo que dificulta el cálculo del promedio final (Colominas et al., 2012). La adición de más ruido a la señal ya contaminada no producirá resultados más limpios, debido a que el ruido contaminante original permanece igual durante todos los ensayos y por lo tanto no puede ser eliminado a través de promedios (Kaslovsky & Meyer, 2010).

Algoritmo 2-2 EEMD

Begin

α : criterio de parada

γ : tendencia

E : energía

N : número de repeticiones

For j = 1 Until N

$d(t) = x(t) + Noise(t)$

```

i = 0
While  $E(x(t)) \geq \gamma$ 
  While  $d(t) \leq \alpha$ 
     $M_i = \text{maxlocal } x(t), m_i = \text{minlocal } x(t)$ 
     $M(t) = \text{Interpolación}(M_i)$ 
     $m(t) = \text{Interpolación}(m_i)$ 
     $e(t) = \frac{[M(t) + m(t)]}{2}$ 
     $d(t) = x(t) - e(t)$ 
  end while
   $IMF_{i,j} = d(t)$ 
   $x(t) = x(t) - IMF_{i,j}$ 
end while
end For
 $IMF_i = \sum_{j=1}^N \frac{IMF_{i,j}}{N}$ 
end

```

- **Completo Ensamble de Descomposición de Modo Empírico con Ruido Adaptativo (CEEMDAN)**

El método CEEMDAN (Algoritmo 2-3) basado en el EEMD, se ha propuesto proporcionar una reconstrucción exacta de la señal original y obtener una mayor separación espectral de los modos, disminuyendo el coste computacional (Torres et al., 2011). El proceso consiste en:

1. Generar N señales de ruido blanco gaussiano, una por cada iteración a realizar.
2. Descomponer a partir de la EMD cada señal de ruido, obteniendo los modos de cada señal.
3. Obtener el primer modo de las IMFs en forma iterada N veces adicionándole ruido blanco Gaussiano y promediando la sumatoria punto a punto de las señales; calculando la nueva señal a partir de la diferencia entre la señal analizada y la IMF obtenida y repitiendo el proceso desde el paso 3. Para calcular el resto de los modos de la señal, se debe agregar a la señal residuo el modo anterior del ruido blanco gaussiano utilizado para calcular la IMF1.

Algoritmo 2-3 CEEMDAN**Begin**

α : criterio de parada
 γ : tendencia
 E : energía
 N : número de repeticiones

For $j = 1$ **Until** N $d(t) = \text{Noise}(t)$ $i = 0$ **While** $E(x(t)) \geq \gamma$ **While** $d(t) \leq \alpha$ $M_i = \text{maxlocal } x(t), m_i = \text{minlocal } x(t)$ $M(t) = \text{Interpolación}(M_i)$ $m(t) = \text{Interpolación}(m_i)$
$$e(t) = \frac{[M(t) + m(t)]}{2}$$
 $d(t) = x(t) - e(t)$ **end while** $\text{NoiseIMF}_{i,j} = d(t)$ $x(t) = x(t) - \text{NoiseIMF}_{i,j}$ $j++$ **end while****end For****While** $E(x(t)) \geq \gamma$ $i = 0$ **For** $j = 1$ **Until** N $d(t) = x(t) + \text{NoiseIMF}_{i,j}(t)$ **While** $d(t) \leq \alpha$ $M_i = \text{maxlocal } x(t), m_i = \text{minlocal } x(t)$ $M(t) = \text{Interpolación}(M_i)$ $m(t) = \text{Interpolación}(m_i)$
$$e(t) = \frac{[M(t) + m(t)]}{2}$$
 $d(t) = x(t) - e(t)$ **end while** $\text{IMF}_{i,j} = d(t)$ $x(t) = x(t) - \text{IMF}_{i,j}$ **end For**
$$\text{IMF}_i = \sum_{j=1}^N \frac{\text{IMF}_{i,j}}{N}$$
 $i++$ **end While****end**

- **Descomposición Rápida de modo empírico (fastEMD)**

Esta técnica (Algoritmo 2-4) consiste en obtener la envolvente superior e inferior, a partir de los máximos y mínimos de la función, unidos por una función diente de sierra en lugar de interpolaciones (*splines*) cúbicas (Blakely, 2005; Yu Lu, 2011) y aplicando una transformada espacial que solo afecta la amplitud y no la distribución temporal de los datos, se logra obtener la IMF. Este método de descomposición permite obtener una única IMF en cada iteración al procesar los datos, el problema con el método es la fuga de ondas de alta frecuencia en el residuo de la función (Yu Lu, 2011).

Algoritmo 2-4 fastEMD

Begin
 α :criterio de parada

 γ : tendencia

 E :energía

 $d(t) = x(t)$
 $i = 0$
While $E(x(t)) \geq \gamma$
While $d(t) \leq \alpha$
 $M_i = \max_{local} x(t), m_i = \min_{local} x(t)$
 $M(t)$ =Interpolación Lineal por Tramos (M_i)

 $m(t)$ = Interpolación Lineal por Tramos(m_i)

$$e(t) = \frac{[M(t) + m(t)]}{2}$$
 $e'(t)$ = Transformación Espacial ($e(t)$)

 $d(t) = x(t) - e'(t)$
end while
 $IMF_i = d(t)$
 $x(t) = x(t) - IMF_i$
 $i++$
end while
end

2.2.2 Análisis de Vibración por Descomposición de Hilbert (HVD)

La técnica HVD permite determinar la frecuencia a priori de una señal desconocida, implementando un filtro pasa-bajas de banda estrecha entre la frecuencia central y la frecuencia de corte en lugar del promedio, para determinar las IF (Funciones Intrínsecas), eliminando las componentes de alta frecuencia debidas a las oscilaciones asimétricas y

dejando las de baja frecuencia sin modificaciones; permitiendo la detección de las componentes que representan la mayor parte de la potencia de la señal. En cada iteración la HVD extrae la componente más lenta de la señal donde la función residual contiene las componentes de baja energía, logrando separar los modos siempre y cuando la diferencia entre las frecuencias sea mayor a la frecuencia de corte (Feldman, 2011).

Este método se basa sobre los siguientes supuestos:

- ✓ La señal subyacente está formada por la superposición de funciones cuasi-armónicas simétricas.
- ✓ La envolvente de cada componente es diferente.
- ✓ Cada componente se debe extender por varios períodos de la señal.

La implementación del método se basa en:

- ✓ La estimación de la IF con mayor contenido de energía.
- ✓ La detección de la envolvente de la IF estimada.
- ✓ La sustracción de dicha componente de la función, generando una función residual con las componentes de baja energía.

La HVD (Algoritmo 2-5) es un método iterativo que permite descomponer una señal en modos a partir de la amplitud y frecuencia instantánea, por medio de un filtro de banda estrecha generando una señal residual con las componentes de baja energía (Feldman, 2011).

Algoritmo 2-5 HVD

Begin

α : criterio de parada
 γ : tendencia
 E : energía
 A_i : amplitud instantánea
 θ_i : frecuencia instantánea

$$d(t) = x(t)$$

$$i = 0$$

While $E(x(t)) \geq \gamma$

$$[A_i, \theta_i] = \text{Transformada de Hilbert Huang}(x(t))$$

```

    e(t) = Ai(t) * cos(θi(t))
    e'(t) = Filtro Pasa Bajas (e(t))
    IMFi = x(t) - e'(t)
    x(t) = x(t) - IMFi
    i++
  end while
end

```

2.2.3 Coeficientes Cepstrales en las Frecuencias de Mel (MFCC)

Son considerados un método eficiente para la extracción de características, el cual es mejorado cuando la información de la energía es adicionada, aunque el ancho de banda de los filtros y el número de filtros no están normalizados hasta ahora (Aggarwal & Dave, 2012).

Los MFCC poseen una escala de transformación lineal por debajo de 1 KHz y logarítmica por encima de esta frecuencia (ver Ecuación (2.4)), además emplean un filtro de preénfasis con el fin de aumentar las altas frecuencias en proporción directa al aumento de amplitud del ruido en dichas frecuencias. Se realiza un análisis por tramas, utilizando un inventariado de 20 a 40 filtros triangulares. Debido a que las características obtenidas a partir de la MFCC son muy sensibles al ruido de fondo, se ha propuesto mejorarlas utilizando algoritmos genéticos (GA) y el método de optimización por enjambre de partículas (PSO), para establecer el número de filtros triangulares y el ancho de banda de los mismos (Aggarwal & Dave, 2012).

$$Mel(f) = 2595 * \log\left(1 + \frac{f}{700}\right) \quad (2.4)$$

Se calculan las variantes de los MFCC a partir de las fórmulas (Xiang Li et al., 2010):

$$\text{If } \frac{R_{IMF_i}}{R_{IMF_1}} < 0.01 \quad (i = 2, 3, \dots, n) \quad (2.5)$$

$$T_r(t) = \sum_i IMF \quad (2.6)$$

$$S_x(t) = X(t) - T_r(t) \quad (2.7)$$

$$\Psi[S_x(i)] = S_x^2(i) - S_x(i+1) * S_x(i-1) \text{ con } i = 1, 2, \dots \quad (2.8)$$

$$C_i = \begin{cases} 1 + \frac{|i-1-\frac{N}{2}|}{10} \\ 1 + \frac{|i-\frac{N}{2}|}{10} \end{cases}, i = \frac{N+1}{2}, 2, \dots, N \quad (2.9)$$

$$W_{IMF_i} = C_i * IMF_i \quad (2.10)$$

$$W_x(t) = \sum_i W_{IMF_i} \quad (2.11)$$

Donde:

R : Tasa de cruce por cero

$X(t)$: Señal original

Ψ : Operador de Energía (TEO)

N : Número de IMFs seleccionados

C_i : Coeficiente de ponderación

W_{IMF_i} : IMFs ponderadas

W_x : Señal reconstruida a partir de la regla de ponderación lineal

2.2.4 Transformada de Hilbert-Huang (HHT)

La HHT es una técnica simple para analizar los cambios de frecuencia y amplitud de una señal en el tiempo, la cual solo puede ser aplicada sobre señales monocomponentes. Esta transformada tiene características de multiresolución, autoadaptabilidad y altamente discernible con la ventaja de depender únicamente de los datos propios de la señal, sin requerir datos previos, donde adicionalmente se puede obtener características locales de la señal.

La transformada de Hilbert (HT) de una función real $x(t)$, resulta de la convolución entre la función a analizar $x(t)$ y el inverso del tiempo $\frac{1}{\pi t}$, lo que enfatiza en las propiedades locales de la función (Tseng et al., 2012) y está definida por (Ecuación (2.12)):

$$H[x(t)] = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (2.12)$$

La HHT consiste en el paso de una función $x(t)$ a través de un sistema, el cual deja la magnitud sin cambio, pero genera un desfase de $\frac{\pi}{2}$ en todas los componentes de frecuencia de la señal, permitiendo la construcción de una señal analítica compleja $Z(t)$ en la que su parte imaginaria es la denominada HHT de $x(t)$ y su parte real es igual a la señal original y su espectro de frecuencias es nulo para frecuencias negativas. Esta función analítica es descrita por (véase Ecuación (2.13)):

$$Z(t) = x(t) + iH[x(t)] = a(t)e^{i\theta(t)} \quad (2.13)$$

$$a(t) = [x(t)^2 + (H[x(t)])^2]^{1/2} \quad (2.14)$$

$$\theta(t) = \arctan\left(\frac{H[x(t)]}{x(t)}\right) \quad (2.15)$$

$$\omega(t) = \frac{d\theta(t)}{dt} \left[\frac{rad}{s} \right] \quad (2.16)$$

$$f(t) = \frac{1}{2\pi} \omega(t) [Hz] \quad (2.17)$$

Donde

$a(t)$: Amplitud instantánea

$\theta(t)$: Fase instantánea

$\omega(t)$: Frecuencia instantánea en *rad/s*

$f(t)$: Frecuencia instantánea en *Hz*

2.3 Modelo Oculto de Markov (HMM)

Los algoritmos de reconocimiento de patrones han sido ampliamente usados para el desarrollo de herramientas de asistencia diagnóstica. Entre estas técnicas se encuentran las basadas en los modelos ocultos de Markov (HMM), un proceso doblemente estocástico,

con un proceso estocástico subyacente que no es observable u oculto, pero se puede observar a través de otro proceso estocástico que produce la secuencia de símbolos observados (L. Rabiner, 1989). El proceso oculto consiste en un conjunto de estados conectados entre sí por las transiciones con probabilidades, mientras que el proceso observado consta de un conjunto de salidas u observaciones, cada una de las cuales pueden ser emitidas por cada estado de acuerdo con alguna función de densidad de probabilidad (*probability density function, pdf*) (Becerra, Orrego, Mejia, & Delgado Trejos, 2012; Shimpi & Patil, 2013). Se ha encontrado que la HMM arroja mejores resultados que la Red Neuronal Artificial (ANN) en la clasificación de las señales del sinoauricular (SA) con 10 enfermedades diferentes (H. Yao et al., 2014) (ver Tabla 2-2).

La segmentación de las señales PCG por latido cardíaco sístole (S1) y diástole (S2) para el análisis de cada uno de los segmentos por separado, es un requerimiento de los algoritmos de clasificación para obtener un rendimiento confiable (Delgado et al., 2009).

Los estados se etiquetan como el conjunto de subíndices $\{0, \dots, N\}$ y por tanto el estado actual en el instante de tiempo t se denota como S_t . No obstante, cabe destacar que aunque los estados del modelo permanecen ocultos, se conocen a priori para una gran mayoría de aplicaciones prácticas. El modelo consta de $(M+1)$ símbolos $\{O_0, O_1, \dots, O_M\}$, los cuales pueden ser continuos o discretos de acuerdo con el modelo oculto de Markov.

Tabla 2-2: Comparación de análisis de diferentes Sonidos Cardiacos a partir de varias técnicas (H. Yao et al., 2014)

Método	Datos HS	Con Segmentación	Con Extracción Características	Técnicas de Clasificación	Precisión Diagnóstico	Tipos de Clasificación	Observaciones
CSA	eGM, Cadionics	No	No	Máquina de Inferencia	74.8%	Clases Múltiples (Normal y 9 CVDs)	Codificación compleja
	Site-sampled	Si	Si	BPNN	80%	Clases Dobles (Normal y Enfermo)	Site-sampled
MFCC	Base de Datos	Si	Si	DTW	92.5% con Ruido; 91.6% con 40dB Ruido Blanco	Clases Múltiples (Normal y 5 CVDs)	Computación Compleja
	Site-sampled, Base de Datos	Si	Si	HMM	99.21%	Clases Múltiples (Normal y 9 CVDs)	Site-sampled, Base de Datos

	<i>Site-sampled</i>	Si	Si	Redes de Crecimiento y Aprendizaje	0,99	Clases Múltiples (Normal y 6 CVDs)	<i>Site-sampled</i>
<i>DWT</i>	<i>Site-sampled</i>	Si	Si	Redes Lineales de Cuantificación Vectorial	0,96	Clases Múltiples (Normal y 6 CVDs)	Tiempo de Computación Corto
	<i>Site-sampled, Base de datos</i>	No	Si	Red Neuronal	92% con Ruido; 90% con 10 dB con Ruido Blanco	Clases Dobles (Normal y Enfermo)	

Un modelo se caracteriza por el conjunto de parámetros de medida de probabilidad

$$\lambda = (A, B, \Pi) \quad (2.18)$$

Donde,

$\Pi = \{\pi_i\}$, distribución de las probabilidades iniciales de los estados

$$\pi_i = P(q_0 = S_i) \quad (2.19)$$

$A = \{a_{ij}\}$, matriz de probabilidades de transición de estados

$$a_{ij}(k) = P(q_{t+1} = S_j | q_t = S_i), 0 \leq i, j \leq N \quad (2.20)$$

La cual indica la probabilidad de pasar al estado S_j estando en el estado S_i . Esta matriz es estocástica por lo que la suma de todos los arcos que salen de un estado es igual a uno (Ecuación (2.21)) y no requiere ser completa, debido a que las transiciones tienen limitaciones.

$$\sum_{j=0}^N a_{ij} \quad (2.21)$$

$B = \{b_j(k)\}$, es el conjunto de parámetros que definen la función densidad de probabilidad de emisión de un símbolo observable en cada caso S_j (véase Ecuación (3.20)).

$$b_{ij}(k) = P(Y_t = O_k | q_t = S_j), 0 \leq j \leq N \quad (2.22)$$

Para una secuencia de estados S_{i_0}, \dots, S_{i_t} , la probabilidad de observar la secuencia de símbolos, está dada por:

$$P(Y_{t_0} = O_0, \dots, Y_t = O_t | q_0 = S_{i_0}, \dots, Y_t = q_t = S_{i_t}) = \prod_{k=0}^t b_{ik}(k) \quad (2.23)$$

2.4 Optimización por Enjambre de Partículas (PSO)

La optimización por nube de partículas u optimización por enjambre de partículas (Algoritmo 2-6), hace referencia a una serie de métodos y algoritmos de optimización heurísticos que evocan el comportamiento de los enjambres de abejas, bandadas de aves, banco de peces e incluso la conducta social humana (Aote et al., 2013).

Algoritmo 2-6 PSO

Begin

$x_i(k)$, es posición actual de la partícula i (iteración k)
 $x_i(k + 1)$: posición de la partícula i en la iteración $k+1$
 $v_i(k)$: velocidad actual de la partícula i (iteración k)
 $v_i(k + 1)$: velocidad de la partícula i en la iteración $k+1$
 c_1 : coeficiente de aprendizaje (coeficiente de aceleración cognitivo)
 c_2 : coeficiente de aceleración social
 r_1 y r_2 : números aleatorios distribuidos uniformemente ($0 \leq r \leq 1.0$)
 w : coeficiente de inercia de las partículas
 p_i : mejor posición de la partícula i en el espacio de búsqueda
 p_{gd} : mejor posición a partir del grupo de partículas
 N : número de partículas

$x_i(k) = rand(N, 1)$

$v_i(k) = rand(N, 1)$

$w = 0.2$

$c_1 = 2.0$

$c_2 = 2.0$

$r_1 = rand()$

$r_2 = rand()$

$k = 0$

$p_i(0) = x_i(k)$

$p_i(1) = v_i(k)$

While $\sum_i(p_i(1) - p_i(0)) \geq 0$

$p_i(0) = p_i(1)$

$v_i(k + 1) = w * v_i(k) + c_1 r_1 (p_i - x_i(k)) + c_2 r_2 (p_{gd} - x_i(k))$

$x_i(k + 1) = x_i(k) + v_i(k + 1)$

$p_i(1) = \max(|x_{i(k)}|)$

$p_d = \max(|x_{(k)}|)$

```
    k++  
end while  
end
```

PSO permite optimizar un problema a partir de una población (llamada nube o enjambre) de soluciones candidatas (llamadas partículas). Dichas partículas se desplazan por todo el espacio de búsqueda conforme a ciertas reglas matemáticas que tienen en cuenta la posición y la velocidad de las partículas. El movimiento de cada partícula depende de su mejor posición obtenida (posición local), así como por las mejores posiciones globales encontradas por otras partículas a medida que recorren el espacio de búsqueda. El proceso se repite con el objetivo, no garantizado, de hacer que la nube de partículas converja rápidamente hacia las mejores soluciones.

PSO es una metaheurística, ya que asume pocas o ninguna hipótesis sobre el problema a optimizar y puede aplicarse en grandes espacios de soluciones candidatas. Sin embargo, como toda metaheurística, PSO no garantiza la obtención de una solución óptima en todos los casos a pesar de su rápida convergencia (Aote et al., 2013).

Capítulo 3 – Marco Experimental

En este capítulo, se describen las diferentes técnicas aplicadas en el desarrollo de la investigación y la metodología propuesta (Figura 3-1).

3.1 Base de Datos

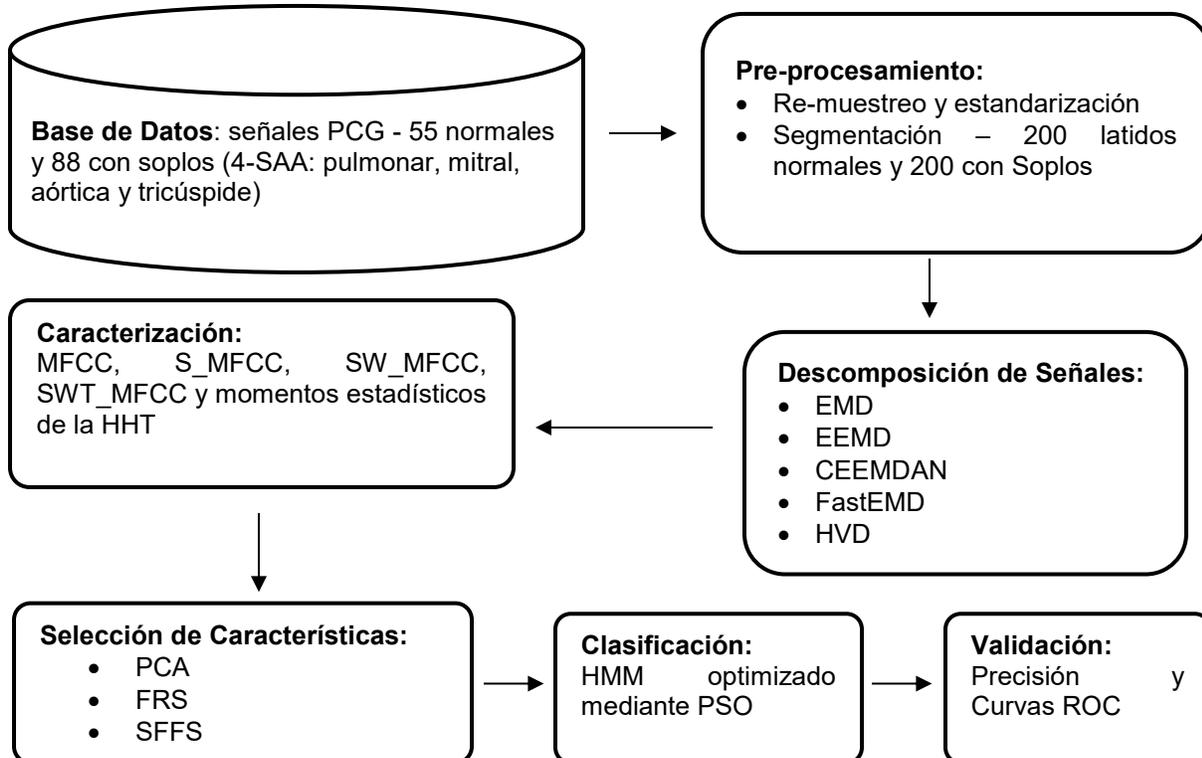
La base de datos de sonidos Fonocardiográficas (PCG), pertenece al grupo de investigación de Control y Procesamiento Digital de Señales de la Universidad Nacional de Colombia Seccional Manizales y a Telesalud de la Universidad de Caldas. Esta consta de 526 señales obtenidas de 55 pacientes etiquetados como normales y 657 señales obtenidas de 88 pacientes con evidencia de algún tipo de soplo cardíaco. Las señales fueron adquiridas sin limitaciones en edad ni sexo, con un estetoscopio electrónico marca WelchAllyn® modelo Meditrón, con una frecuencia de muestreo de 44.1 KHz y con una precisión de 16 bits, dentro de una cabina acústica del Hospital Infantil Universitario “Rafael Henao Toro”, luego de haber valorado el estado clínico de cada sujeto y obtenido su respectivo consentimiento informado. Las señales fueron obtenidas estando cada sujeto en posición decúbito dorsal, desde los cuatro focos de auscultación cardíaca en inspiración y expiración, con una duración aproximada de 8 segundos. Finalmente, se eligieron 400 latidos individuales, 200 normal y 200 con evidencia de soplo cardíaco según una inspección visual y audible por los cardiólogos.

3.2 Metodología Propuesta

Para el primer objetivo específico, se representaron las señales PCG por medio de un conjunto de características con Coeficientes Cepstrales en las Frecuencias de Mel (MFCC) y los momentos estadísticos de la Transformada de Hilbert Huang (HHT) obtenidas del análisis de las señales mono-componentes obtenidas en la descomposición basada en el

Descomposición Modo Empírico (EMD) o alguna de sus variantes; implementando además un análisis de relevancia sobre el conjunto de características con técnicas como Análisis de Componentes Principales (PCA), Selección Secuencial hacia Adelante (SFFS) y Conjuntos de Aproximación Difusos (FRS).

Figura 3-1: Metodología propuesta



Acerca de “Proponer un esquema de clasificación de señales fonocardiográficas basado en un modelo HMM continuo y optimizado mediante algoritmos de enjambre para su topología y aprendizaje”, para lo cual se determinaron los atributos óptimos para la inicialización del Modelos Ocultos de Markov (HMM) en relación al número de estados y el número de gaussianas. También se reemplazó el criterio de convergencia Expectativa de Maximización (EM) por el método de Optimización por Enjambre de Partículas (PSO).

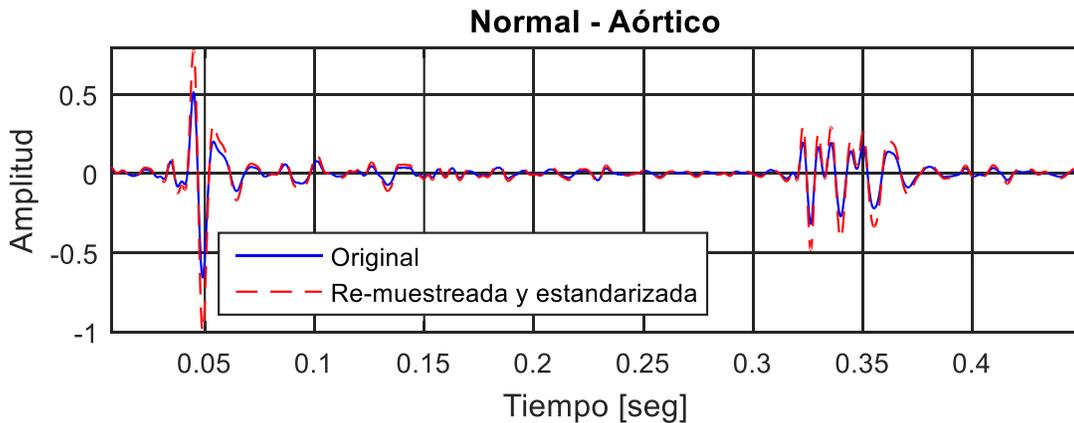
Con la finalidad de “Validar la metodología de representación y optimización mediante tasas de acierto, curvas ROC y eficiencia de procesamiento respecto a algoritmos convencionales”, se tabularon los datos obtenidos a partir de la validación cruzada 70-30

con 30 folds, (repeticiones) sobre el conjunto de características seleccionadas a partir del análisis de relevancia.

3.3 Pre-Procesamiento

Las señales PCG de la base de datos utilizada tienen componentes de frecuencia entre 10 Hz y 1 KHz aproximadamente, una amplitud no normalizada y frecuencia de muestreo de 44.1 KHz que se considera excesiva respecto al teorema de Nyquist, que es suficiente para evitar el *aliasing*, pero demanda un costo computacional muy elevado para su procesamiento. Por lo anterior, para obtener un adecuado desempeño del clasificador, se realizó un re-muestreo a 4410 Hz y una estandarización de amplitud bipolar (Chauhan et al., 2008) entre -1 y 1 (Figura 3-2).

Figura 3-2: Señal PCG con normalización bipolar



$$x(k)_{norm} = \frac{x(k)}{\max(|x(k)|)} \quad (3.1)$$

Donde, $x(k)$ es la señal a normalizar y $x(k)_{norm}$ es la señal con normalización bipolar (Chauhan et al., 2008)

$$x(k)_{norm} = \frac{x(k) - x_{min}(k)}{\max(|x(k)|)} \quad (3.2)$$

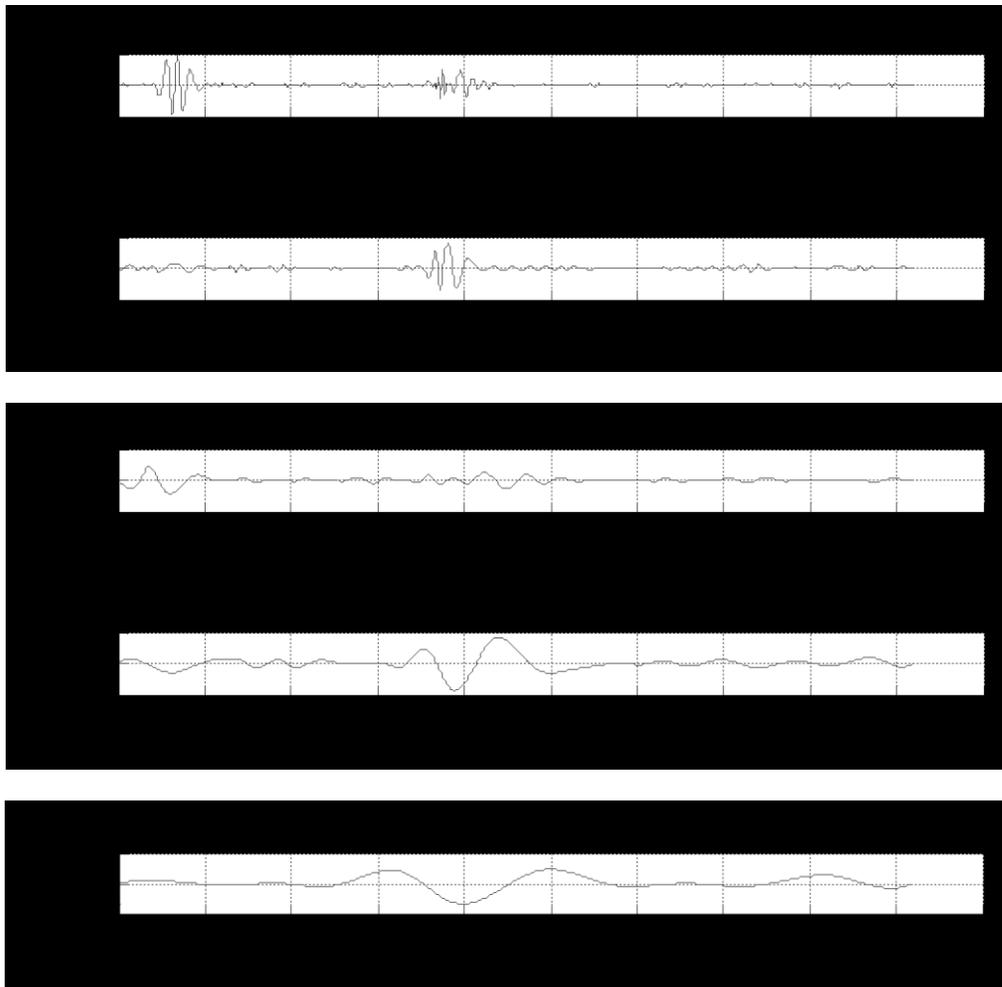
Con $x(k)$ es la señal a normalizar y $x(k)_{norm}$ es la señal con normalización unipolar

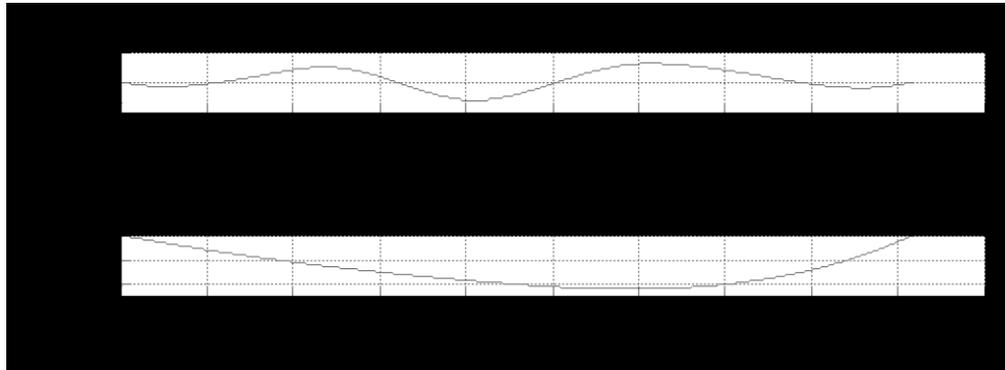
3.4 Descomposición de señales

3.4.1 Descomposición de modo empírico (EMD)

EMD es un método que permite separar una señal en diferentes componentes de acuerdo con sus escalas (Figura 3-3), a partir del cálculo de las Funciones de Modo Intrínseca (IMF). El cálculo de las IMFs, se basa en la envolvente obtenida a partir de los mínimos y máximos locales (formados por medio de ajuste spline cúbico) y son estimadas mediante un procedimiento iterativo denominado *sifting* (N. E. Huang, 2005; Kopsinis & McLaughlin, 2009; Rilling et al., 2003).

Figura 3-3: Descomposición de la señal PCG con EMD

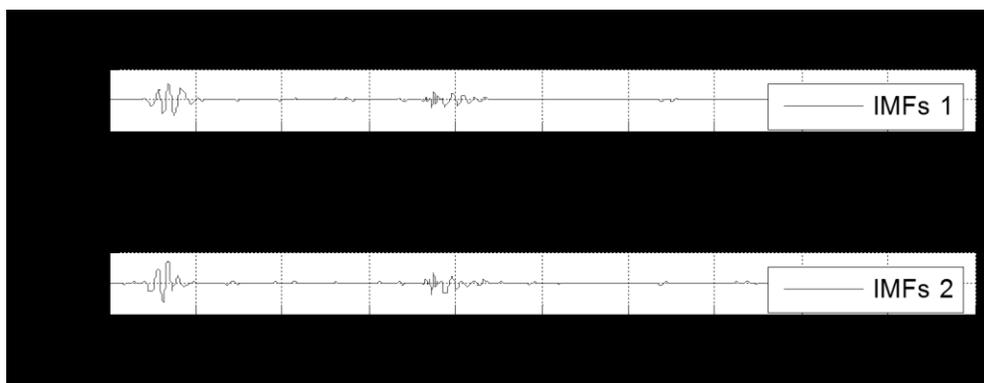


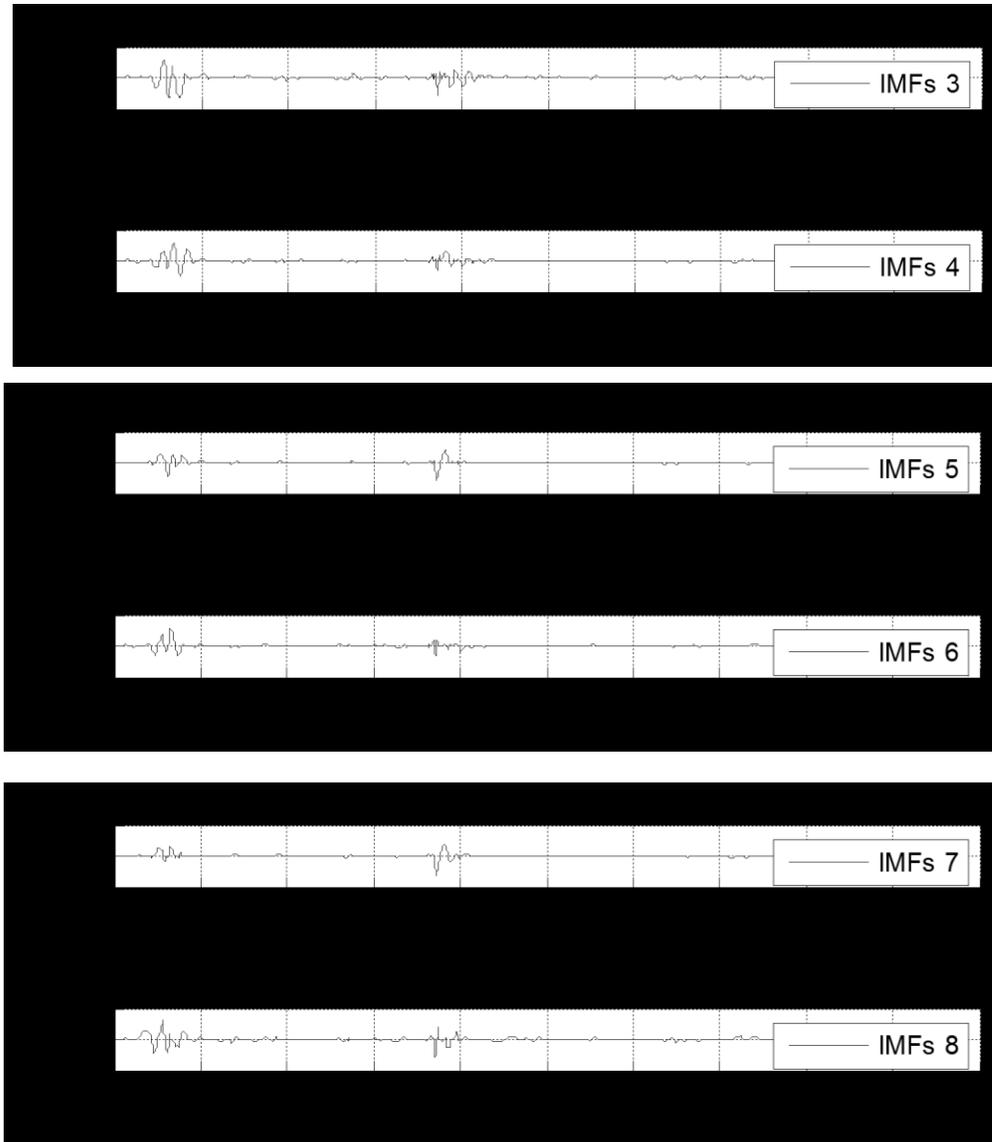


3.4.2 Descomposición rápida de modo empírico (fastEMD)

La principal dificultad en el cálculo de la IMF, es la generación de la envolvente de la señal a partir de curvas diferenciables definidas en tramos por polinomios o splines. El fastEMD al igual que la EMD convencional, obtiene los máximos y mínimos de la señal analizada y con estos genera las envolventes, pero en este caso se realiza a partir de la unión de los máximos con segmentos de recta, de igual forma para los mínimos, lo cual implica que dicha envolvente es única para el conjunto de puntos (tanto máximos como mínimos), se promedian las envolventes y posteriormente se aplica una transformación espacial de la IMF obtenida para llevarla al dominio del tiempo (Figura 3-4).

Figura 3-4: Descomposición de la señal PCG con fastEMD





3.4.3 Ensamble de descomposición de modo empírico (EEMD)

EEMD (Figura 3-5 y 3-6) utiliza hábilmente las perturbaciones de ruido para forzar el algoritmo a explorar todas las frecuencias mientras minimiza el ruido empujando el algoritmo al régimen de fuga espectral. El ruido se añade a la señal original y una descomposición estándar EMD se lleva a cabo. Esto se repite con diferentes realizaciones de ruido para un número fijo de veces. Las IMFs resultantes de cada ejecución se promedian, produciendo un número de "ensembles" (Kaslovsky & Meyer, 2010). A nivel experimental se han realizado varias pruebas con las IMFs de la señal con ruido,

demostrando que el IMF 1 contiene el ruido y el IMF 2 representa la transición del ruido a la señal. Es claro que para producir una frecuencia instantánea significativa, el IMF 1 debe ser desechado y la IMF 2 debe incluirse, ya que contiene casi la totalidad de la energía, pero será problemático, ya que también contiene ruido (Kaslovsky & Meyer, 2010).

Figura 3-5: Descomposición de la señal PCG con EEMD (basada en EMD)

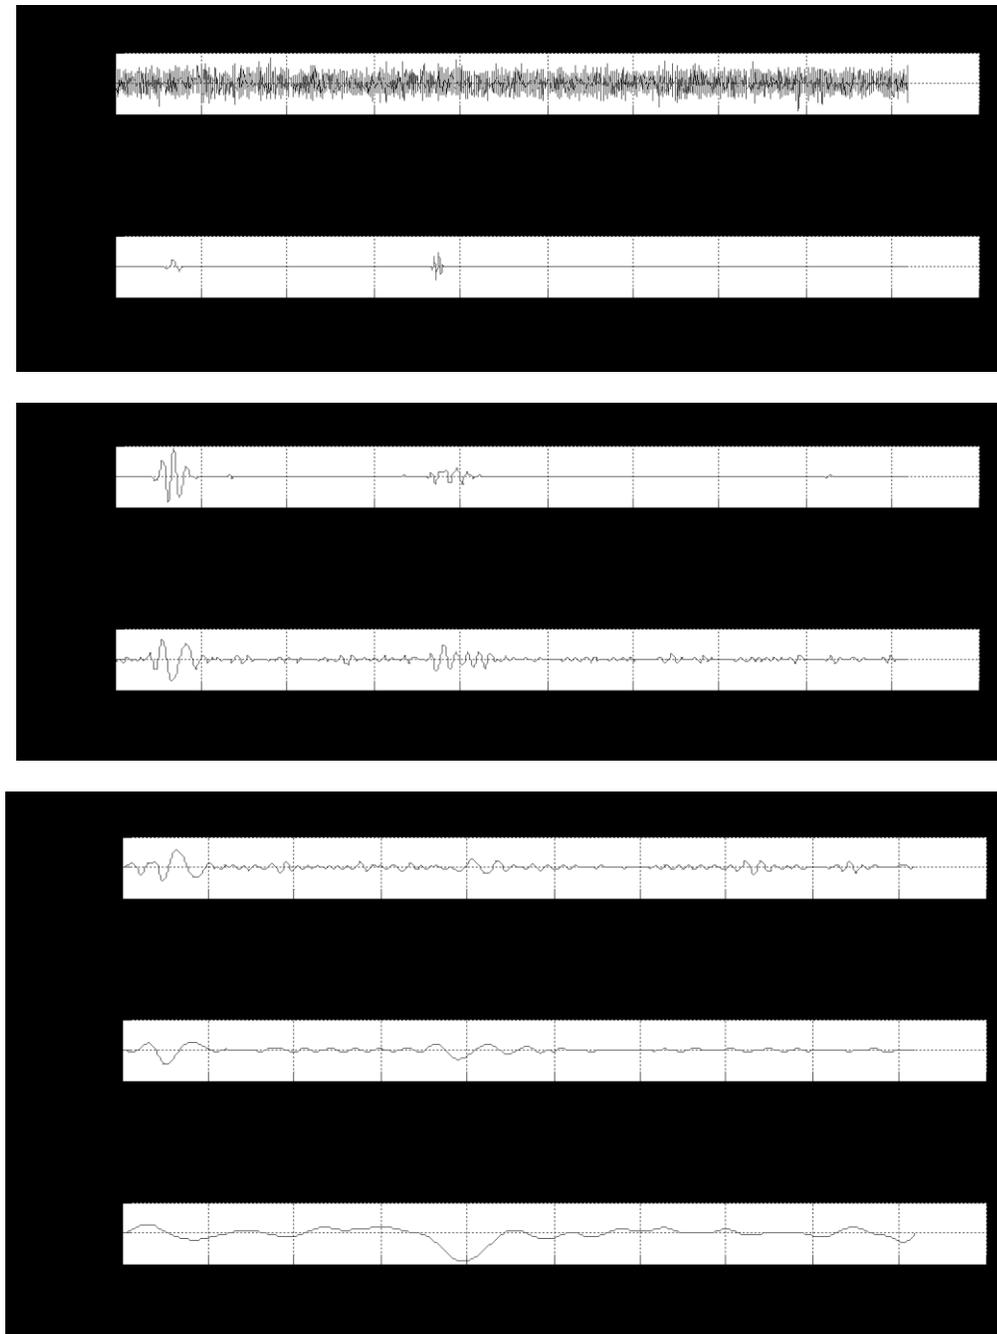
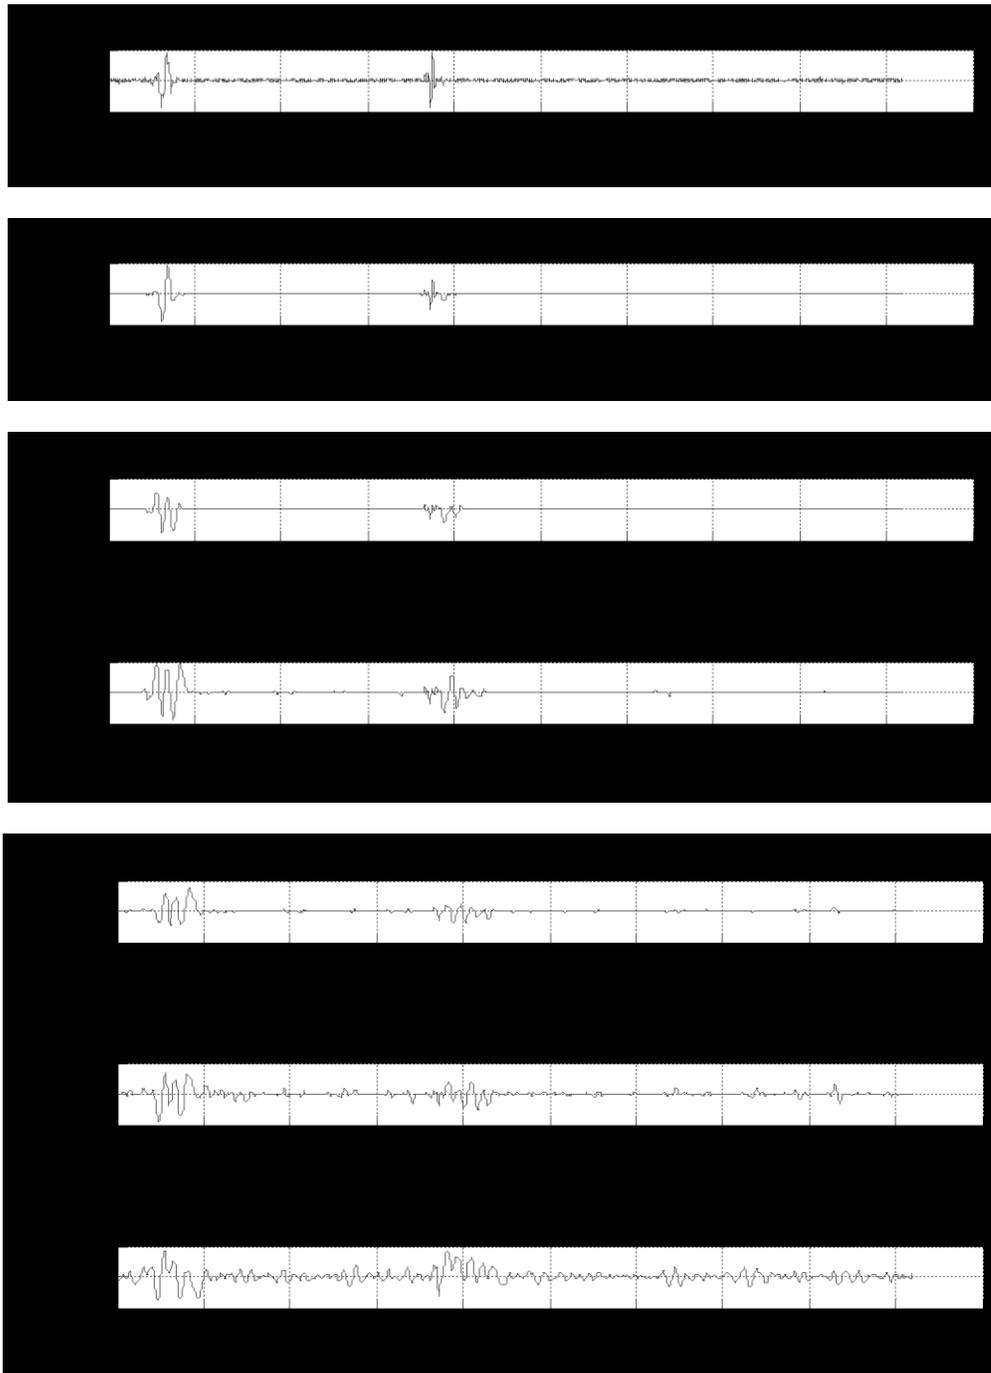


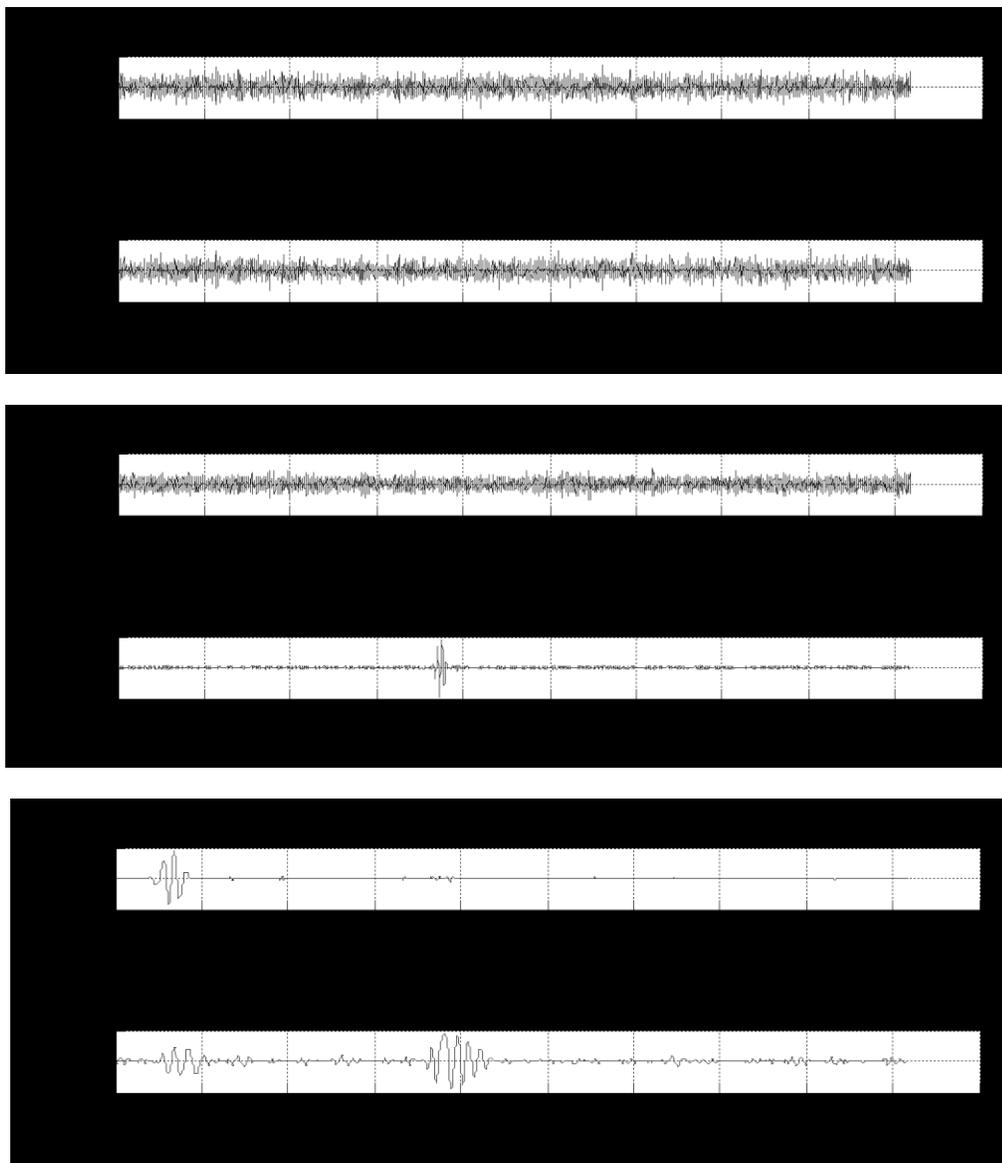
Figura 3-6: Descomposición de la señal PCG con EEMD (basada en fastEMD)



3.4.4 Completo ensamble de descomposición de modo empírico con ruido adaptativo (CEEMDAN)

El CEEMDAN (Figura 3-7 y 3-8) añade un ruido particular, en cada etapa, y logra una descomposición completa sin error de reconstrucción, sin embargo la amplitud del ruido utilizado sigue siendo una cuestión abierta (Colominas et al., 2012); tiene la ventaja de que requerir menos de la mitad de las iteraciones que requiere el EEMD y que la señal original puede ser reconstruida exactamente sumando los modos (Torres et al., 2011).

Figura 3-7: Descomposición de la señal PCG con CEEMDAN (basada en EMD)



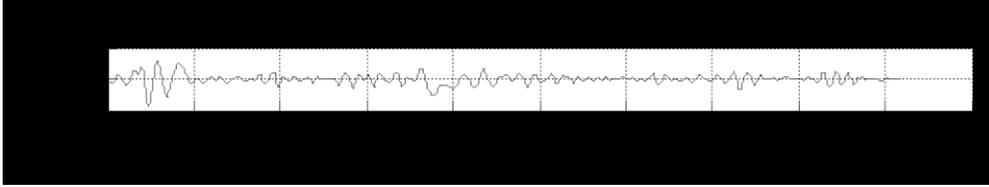
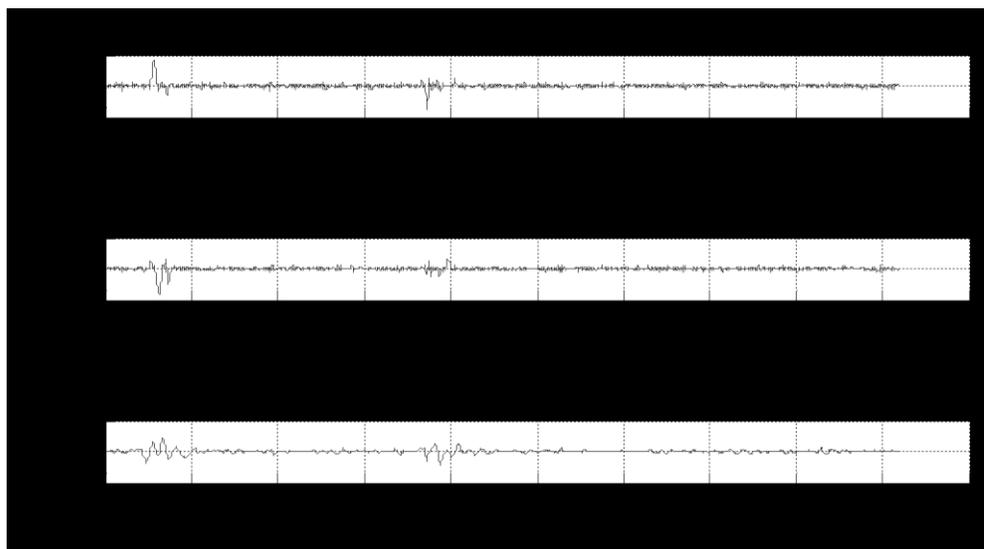
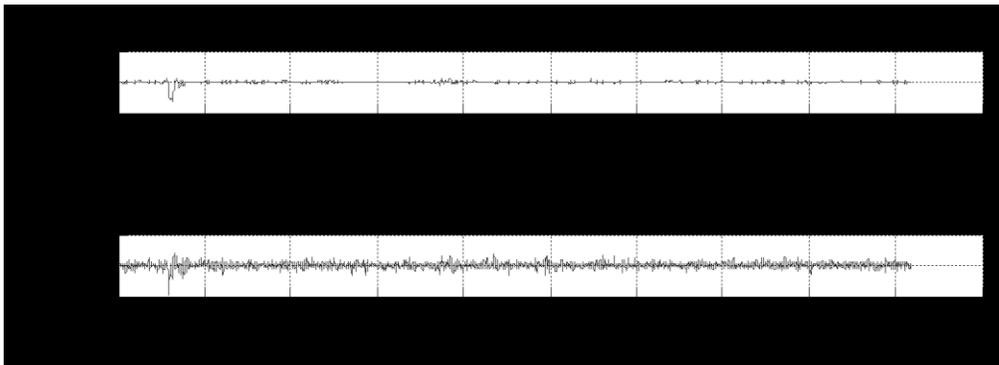
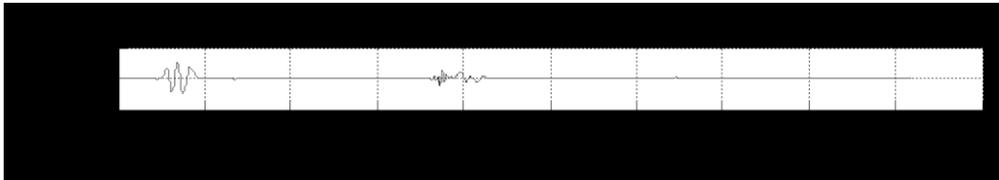
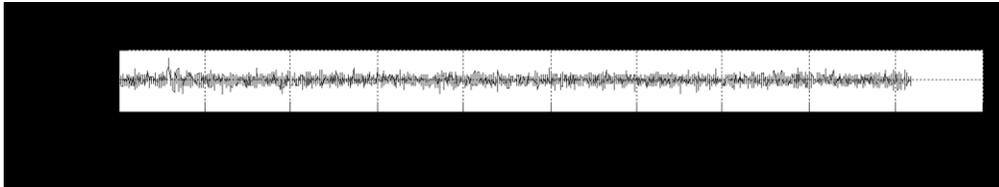


Figura 3-8: Descomposición de la señal PCG con CEEMDAN (basada en fastEMD)

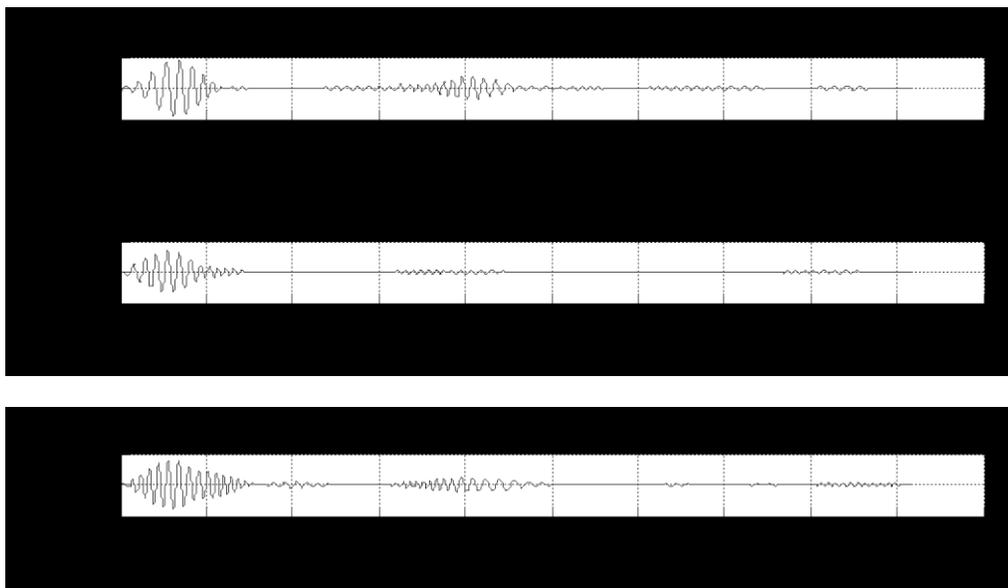


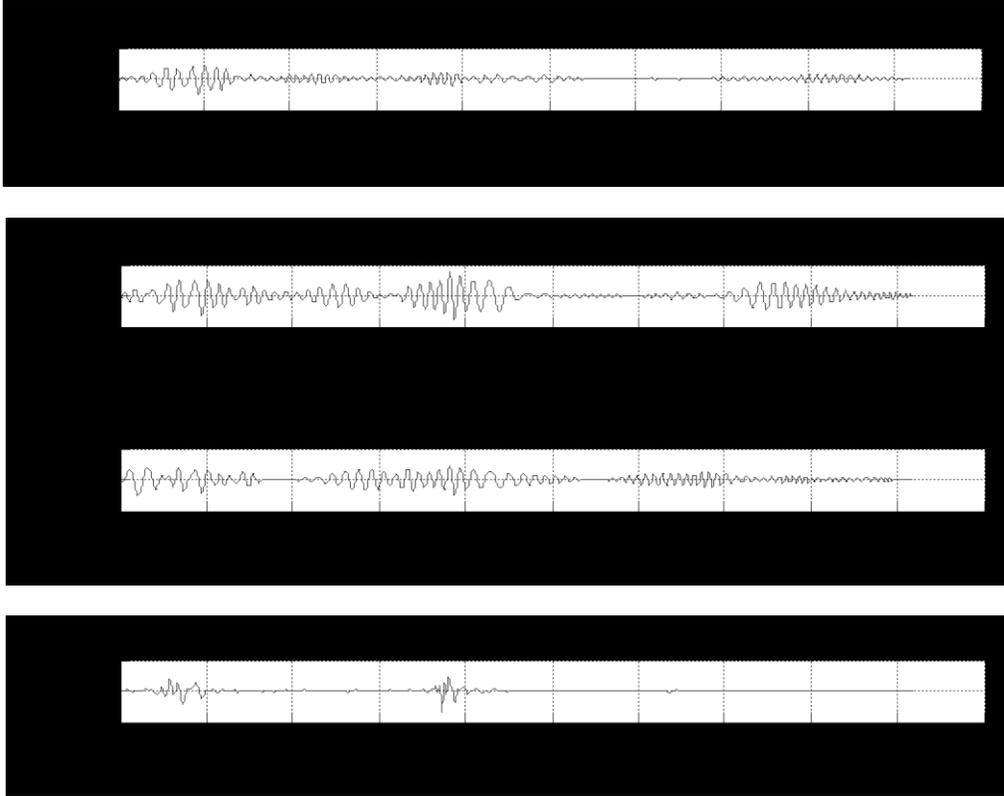
3.4.5 Análisis de Vibración por Descomposición de Hilbert (HVD)

Un filtro pasa-bajas elimina todos los componentes de alta frecuencia fuera de la frecuencia de corte, dejando los componentes de baja frecuencia de la Frecuencia Instantánea (IF) sin modificaciones. En cada iteración después de restar la componente obtenida, a la IF residual se le aplica un filtro de banda estrecha a la señal alrededor de su frecuencia central, y la frecuencia de corte de la IF es igual a la frecuencia de ancho de banda relativa de la señal. El procedimiento se repite hasta que la diferencia entre las frecuencias es menor que el valor de la frecuencia de corte (Feldman, 2008).

El método HVD (Figura 3-9), además de la banda ancha, también permite la descomposición de las señales multicomponentes de banda estrecha, pero requiere registros de datos más largos que los requeridos por el EMD. El EMD y el HVD son algoritmos iterativos para la extracción secuencial de componentes de acuerdo con el enfoque *sifting*, la extracción de una componente de banda estrecha resulta en la disminución del ancho de banda de espectro de la señal residual (Feldman, 2008).

Figura 3-9: Descomposición de la señal PCG con HVD





3.5 Espacio de Representación

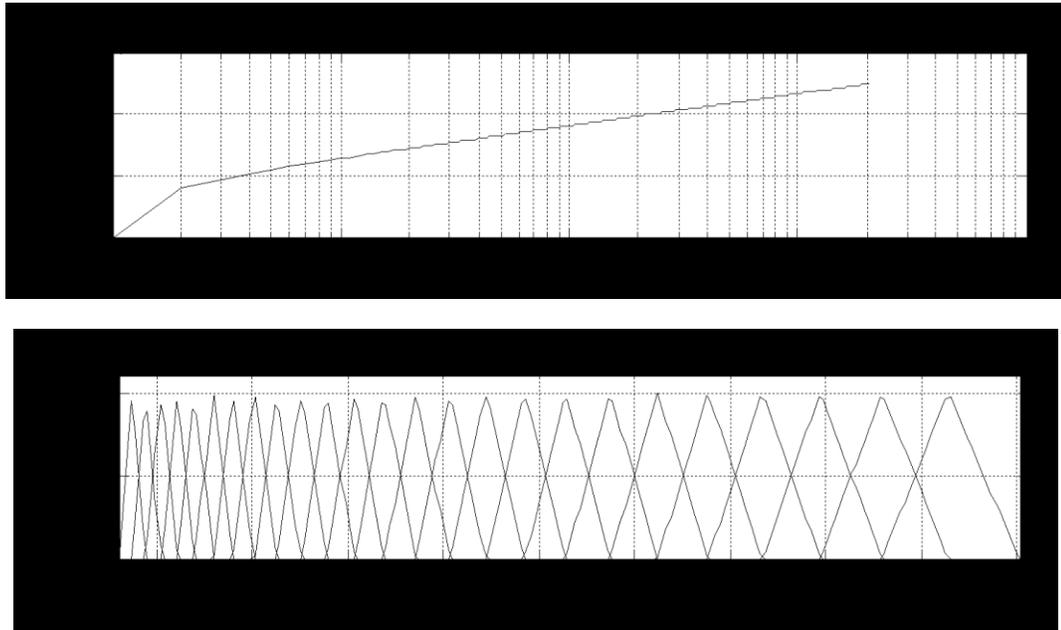
Los sistemas de reconocimiento de patrones, requieren la conversión de las señales en algún tipo de representación paramétrica para su procesamiento. Así, después del pre-procesamiento de la señal, se generaron diferentes espacios de representación para cada base de datos, a partir de los MFCC aplicados directamente a la señal PCG y a los constructos resultantes de la suma de componentes de la señal, obtenidos por medio de las técnicas de descomposición de señales (EMD / fastEMD / EEMD / CEEMDAN / HVD).

3.5.1 Coeficientes Cepstrales en la escala de Frecuencias Mel (MFCC)

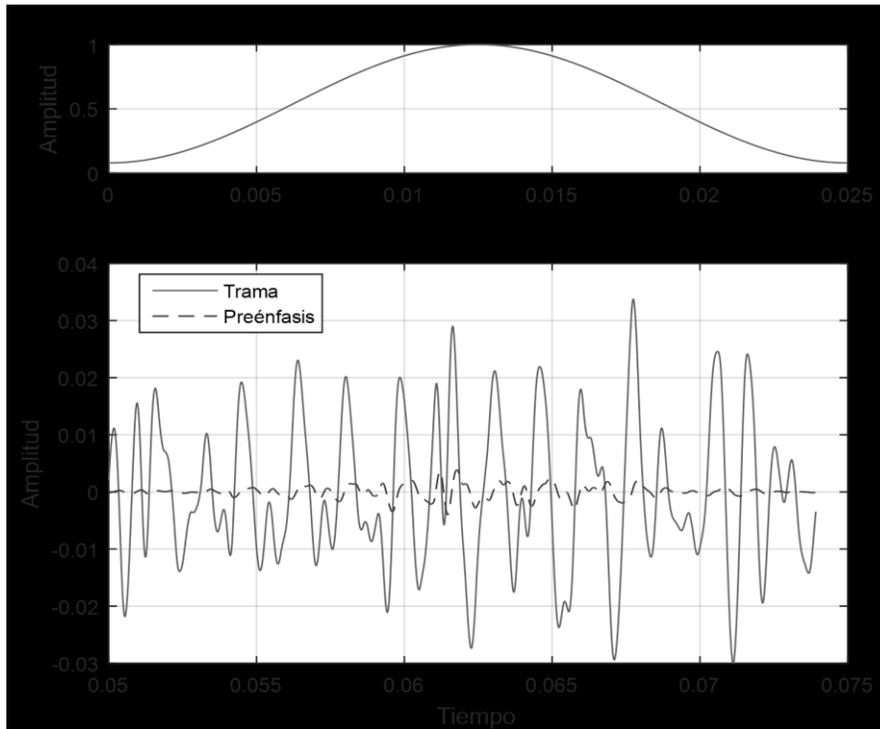
Los MFCC son coeficientes obtenidos de la transformada discreta del coseno, que permiten representar aproximadamente el sistema auditivo humano, mediante la obtención de vectores de coeficientes cepstrales, donde el espaciamiento en frecuencia no es lineal, sino que se distribuye en una escala perceptual tipo Mel, utilizando un banco de filtros

triangulares (Figura 3-10) a partir de esta escala (Chauhan et al., 2008; Kamarulafizam et al., 2007a).

Figura 3-10: Escala de Mel y del banco de filtros triangulares aplicados

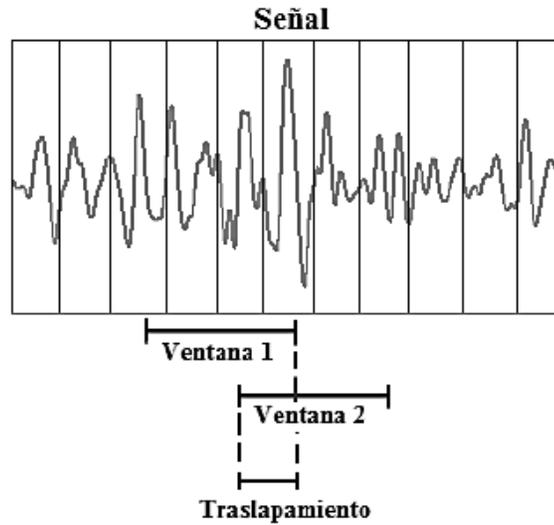


Para el análisis espectral de las señales PCG se debe realizar un ventaneo para que sus características espectrales sean estacionarias en el intervalo de duración de la ventana. En el ventaneo se hace un agrupamiento de la señal en conjuntos de N elementos y se multiplican por una ventana de tipo Hamming (ver Figura 3-11). Este ventaneo debe tener solapamiento, para no perder información entre ventanas, teniendo en cuenta que si las características de la señal varían rápidamente, las ventanas deberán ser más cortas para poder detectar los cambios en el tiempo y si la amplitud de la ventana se reduce, también lo hace la resolución en la frecuencia.

Figura 3-11: Ventana de Hamming y trama de la señal analizada

Los MFCC son estimados utilizando 25 filtros triangulares en el dominio de Mel y ventanas deslizantes con solapamiento del 40% (Figura 3-12), para un total de 7 ventanas sobre cada latido y constructo obtenido por medio de la EMD. Estos constructos, fueron obtenidos descomponiendo las señales PCG en n IMF, buscando realzar la información de los soplos y atenuando el ruido. De igual forma se calcularon los primeros 4 momentos estadísticos (media, varianza, kurtosis y *skewness*), la entropía a los parámetros instantáneos obtenidos a partir de la ecuación característica de los constructos obtenidos y la energía de Shannon (Andrés et al., 2007; Müller-Karger et al., 2008), para un total de 12 características adicionales.

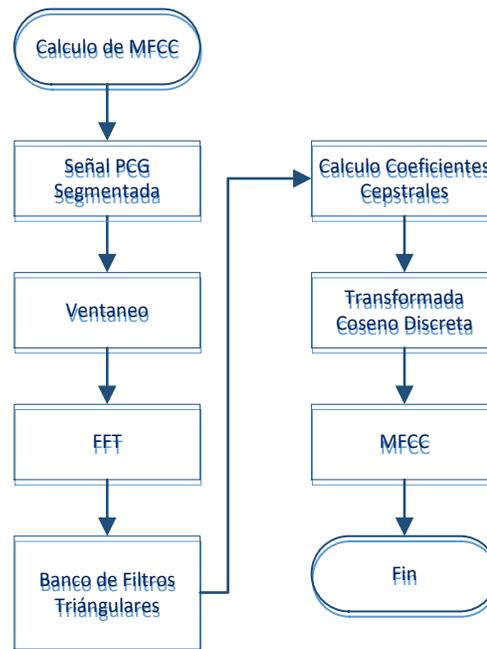
Figura 3-12: Solapamiento (Becerra Botero, 2013)



Para la extracción de características con los MFCC (Figura 3-13) y sus 4 variantes (S_MFCC, ST_MFCC, SW_MFCC y STW_MFCC), se obtienen 12 coeficientes por ventana de Hamming, para un total de 5 ventanas, despreciando el coeficiente 0 por su poca fiabilidad y considerado como el promedio de energías de cada banda de frecuencia de la señal analizada. Además se determinan 11 momentos estadísticos y el coeficiente de energía de Shannon (ver Tabla 3-1).

Tabla 3-1: Distribución de la matriz de características

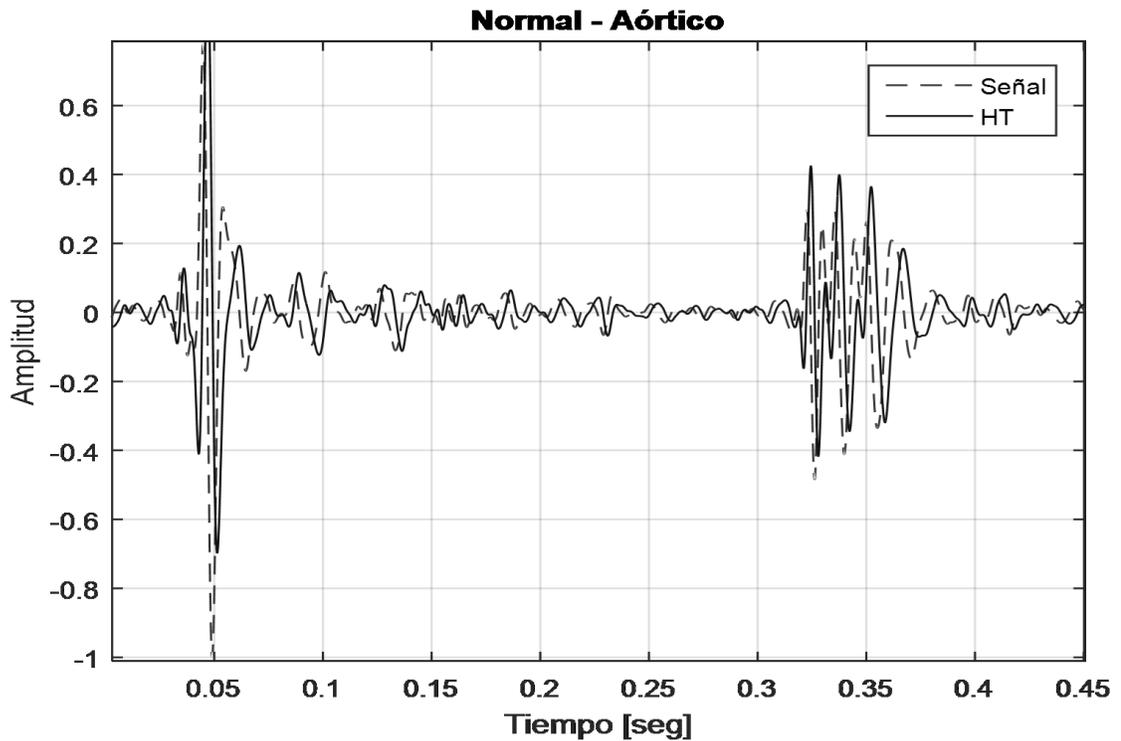
Coeficientes MFCC (60 Coeficientes x Variante)					
1 - 60	61 - 120	121 - 180	181 - 240	241 - 300	
MFCC	S_MFCC	ST_MFCC	SW_MFCC	STW_MFCC	
Momentos Estadísticos					
301	302	303	304	305	306
std	std	var	var	0.5*sum	media
($H(cte,w,a)$)	($H(t,cte,a)$)	($H(cte,w,a)$)	($H(t,cte,a)$)	(($H(cte,w,a)$))	($ H(cte,w,a) $)
307	308	309	310	311	312
max	kurtosis	skewness	entropía	entropía	entropíaShannon
($ H(cte,w,a) $)	($H(cte,w,a)$)	($H(cte,w,a)$)	(($H(t,cte,a)$))	(($H(cte,w,a)$))	(($H(cte,w,a)$))

Figura 3-13: Cálculo de los MFCC

3.5.2 Momentos Estadísticos - Transformada de Hilbert-Huang (HHT)

La transformada de Hilbert-Huang se basa en la transformada de Hilbert, la cual calcula una componente imaginaria y la agrega a la señal, produciendo un desfase con respecto a la señal original (Figura 3-14); luego se toma la nueva señal y sobre esta se calculan las señales correspondientes a la amplitud instantánea $A(t)$, frecuencia instantánea $f(t)$ y la fase instantánea $\theta(t)$.

Figura 3-14: Señal original y señal analítica



A partir de las funciones obtenidas con la HHT, se calculan los momentos estadísticos:

- El primer momento estadístico, denominado la media (μ_X), es la medida del valor central de la variable aleatoria, el cual permite determinar el promedio de las características espaciales. Siendo $f_x(x)$ la función de densidad de probabilidad.

$$\mu_X = E[X] = \int_{-\infty}^{\infty} x f_x(x) dx \quad (3.3)$$

- El segundo momento, la varianza, proporciona información sobre la variabilidad (dispersión y expansión), de un conjunto de datos. También se conoce como el cuadrado de la desviación estándar (σ_x)

$$\sigma_x^2 = E[(X - \mu_X)^2] = \int_{-\infty}^{\infty} (x - \bar{X})^2 f_x(x) dx \quad (3.4)$$

- El tercer momento, la medida de asimetría o *skewness* (λ_x), tiene como objetivo estudiar la deformación horizontal de los valores de la variable respecto al valor central de la media y la concentración de la variable hacia uno de sus extremos.

$$\lambda_x = E[(X - \mu_x)^3] \quad (3.5)$$

- El cuarto momento, denominado kurtosis ($\hat{\gamma}_x$), pretende comparar la curva de una distribución con la curva de la variable Normal, proporcionando información de la figura de la distribución, cuya forma puede ser leptocúrtica si la kurtosis es mayor que 3, mesocúrtica si la kurtosis es igual a 3, es decir, la distribución de los datos corresponde a la de una variable normal, o, platicúrtica si es menor que 3.

$$\hat{\gamma}_x = E[(X - \mu_x)^4] \quad (3.6)$$

Los métodos de descomposición basados en la transformada de Hilbert (HT), se dedican principalmente a la descomposición de señales oscilantes cuasi periódicas; tales tipos de señales oscilantes podrían ser, por ejemplo: no estacionarias, vibraciones moduladas de múltiples componentes (similares a un rotor en puesta en marcha) o a la vibración de apagado, o el movimiento de sistemas dinámicos no lineales (Feldman, 2008).

3.6 Análisis de Relevancia

El análisis de relevancia es la selección de características con el objetivo de reducir dimensiones y evitar el incremento exponencial del número de señales PCG necesarias para el entrenamiento de un sistema automático inteligente, es requerida la etapa de extracción/selección de características para obtener dicho espacio de representación (Orrego & Delgado, 2011) e identificar y remover las variables que no contribuyen al proceso de clasificación (información redundante e irrelevante) (Deisy et al., 2007). La selección de características es un proceso que permite la obtención de un subconjunto de características estimado mediante una función de evaluación, que se compara constantemente con el anterior hasta obtener el mejor de ellos por medio del criterio de parada (Dash & Liu, 1997).

En este estudio, se utilizaron los selectores basados en los algoritmos: *Fuzzy Rough Set* con entropía (FRS-E), el *Sequential Forward Feature Selection* (SFFS) y el *Principal Component Analysis* (PCA).

3.6.1 Análisis de Componentes Principales (PCA)

PCA tiene como objetivos fundamentales comprimir el tamaño del conjunto de datos generando un sub-espacio de bases mutuamente ortogonales (Morchid et al., 2014) llamadas componentes principales preservando al máximo la varianza del conjunto de datos (S. Huang et al., 2015).

Las componentes principales, son nuevas variables que se obtienen como combinaciones lineales de las variables originales. El primer componente principal es obligado a tener la mayor varianza posible del conjunto de datos. A continuación, el segundo componente es calculado bajo la restricción de ser ortogonal a la primera componente y tener la mayor varianza posible (Morchid et al., 2014), los otros componentes se calculan de la misma manera. Dichas componentes se interpretan geoméricamente como las proyecciones de las observaciones sobre los componentes principales obtenidos a partir de la descomposición en valores singulares (SVD) del conjunto de datos X .

3.6.2 Fuzzy Rough Sets (FRS)

La selección de características *fuzzy rough* (FRS) proporciona un medio por el cual datos ruidosos de valor real o discreto (o la mezcla de ambos) pueden ser efectivamente reducidas sin necesidad de información proporcionada por el usuario. Además esta técnica puede ser aplicada a datos con atributos de decisión continuo o nominal, y como tal se puede aplicar a la regresión, así como a conjuntos de datos de clasificación (Jensen & Shen, 2008).

3.6.3 Selección Secuencial Hacia Adelante (SFFS)

A partir de *Sequential Forward Selection* (SFS) y *Sequential Backward Selection* (SBS) se evoluciona a las técnicas *Sequential Forward Floating Selection* (SFFS) y *Sequential Backward Floating Selection* (SBFS) que permiten la selección de características incluidas o removidas, mejoran el costo computacional de una forma aceptable (Tan, Pu, & Zheng, 2014).

Este método tiene dos componentes:

- Una función objetivo llamada criterio, que busca minimizar sobre todos los subconjuntos de características factibles. Los criterios comunes son: el error cuadrático medio (para los modelos de regresión) y la tasa de errores de clasificación (para los modelos de clasificación).
- Un algoritmo de búsqueda secuencial, el cual añade o elimina características de un subconjunto candidato al evaluar el criterio. Desde una comparación exhaustiva del valor del criterio en todos los subconjuntos 2^n de un conjunto de datos con n característica es típicamente no factible (dependiendo del tamaño de n y el coste de la función objetivo), las búsquedas secuenciales se mueven en una sola dirección, siempre creciente o siempre en contracción para establecer los candidatos.

El método tiene dos variantes:

- Selección secuencial hacia adelante (SFS), en el que las características se añaden secuencialmente a un conjunto de candidatos vacío hasta que la adición de nuevas características no disminuye el criterio.
- Selección hacia atrás secuencial (SBS), en el que las características se eliminan secuencialmente a partir de un conjunto candidato completo hasta que la eliminación de otras características no aumenta el criterio.

3.7 Entrenamiento y clasificación

Un clasificador recibe una descripción de un objeto para ser catalogado, decide la clase de objetos a la que pertenece y entrega como salida la etiqueta de la clase apropiada. Para un sistema de decisión, cada registro contiene un conjunto de atributos donde uno de los atributos es la clase. Encontrar un modelo para el atributo de la clase como una función de los valores de los otros atributos, es la tarea fundamental de un clasificador, para ello normalmente la base de datos es dividida en dos subconjuntos, uno de entrenamiento que se utiliza para construir el modelo y uno de prueba para determinar la precisión del modelo o validarlo. Un regla común para dividir la base de datos es utilizar el 70% para entrenamiento y el 30% para validación, sin embargo, esta división es usualmente aleatoria, con el fin de garantizar que ambos subconjuntos son muestras aleatorias de la misma distribución, también puede ser razonable hacer un muestreo estratificado, lo que significa asegurarse de que cada clase está presente en la misma proporción en los subconjuntos de entrenamiento y validación (Becerra Botero, 2013).

3.7.1 Naive Bayes

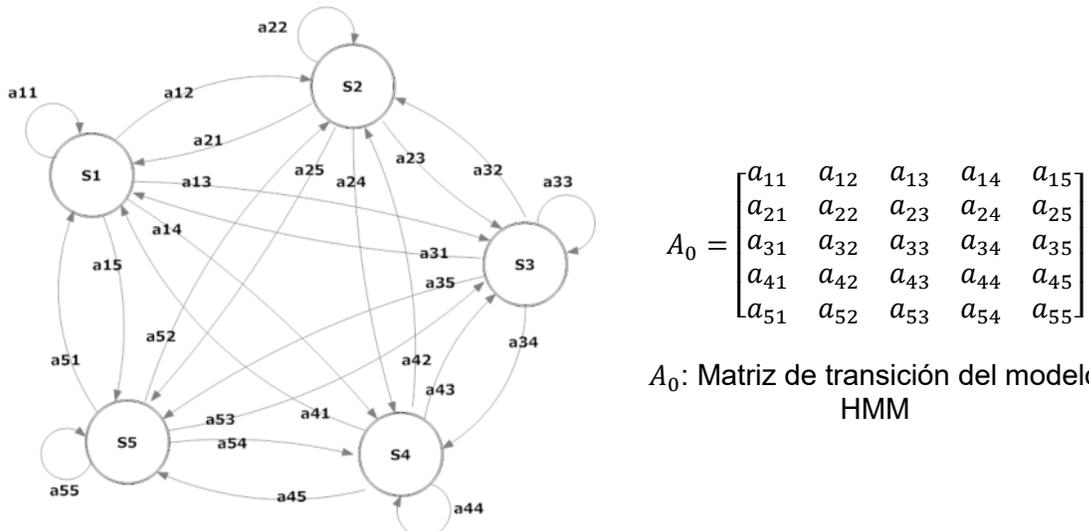
Las redes Bayesianas son consideradas como un método óptimo en la tarea de clasificación, no sólo porque ofrecen un análisis cualitativo de los datos mediante la correlación entre sus atributos, sino también porque dan cuenta de la importancia cuantitativa de esos atributos mediante una medida probabilística, lo que hace la diferencia fundamental de las redes Bayesianas respecto a otros métodos, como árboles de decisión y redes neuronales las cuales no proporcionan una medida cuantitativa de la clasificación. Usar el teorema de Bayes en cualquier problema de aprendizaje automático (en especial los de clasificación) permite estimar las probabilidades a posteriori de cualquier hipótesis consistente con el conjunto de datos de entrenamiento, para así escoger la hipótesis más probable; para estimar estas probabilidades se han propuesto numerosos algoritmos, entre los que cabe destacar el algoritmo Naive Bayes (Becerra Botero, 2013).

3.7.2 Modelos Ocultos de Markov (HMM)

La palabra estocástico se deriva del griego “*stochazesthai*”, que significa apuntar a un objetivo, por lo tanto se denomina proceso estocástico a toda variable que evoluciona a lo largo del tiempo de forma total o parcialmente aleatoria y son utilizados para conocer el desarrollo futuro de los procesos a lo largo del tiempo, y predecir el comportamiento de los fenómenos.

En la metodología propuesta en este trabajo para el análisis de las señales PCG se utilizó un clasificador HMM Ergódico Continuo (Figura 3-15).

Figura 3-15: Descripción del Modelo Ergódico de 5 estados utilizado (Becerra Botero, 2013)



3.7.3 Modelos Ocultos de Markov con Aprendizaje Optimizado por PSO (PSOHMM)

En PSO, cada partícula se desplaza a través del espacio de búsqueda multidimensional, ajustando su posición en dicho espacio de acuerdo a su trayectoria y de la mejor posición encontrada por sí mismo y la de sus vecinos, para posicionarse hacia una solución óptima (Alfi, 2011). Esto significa que si una partícula descubre una nueva solución prometedora, las demás partículas se moverán más cerca de esta, explorando la región donde se encuentra (Z. Wang et al., 2007); además se introduce una masa de inercia dinámica

w para mejorar la precisión de PSO (Alfi, 2011) con un w grande se mueve rápidamente en el espacio para una búsqueda global y con un w pequeño se realiza una búsqueda local.

3.8 Análisis de Datos Experimentales

La validación de resultados, se realiza sobre el clasificador previamente entrenado con un conjunto de señales que no fueron utilizadas en la etapa de entrenamiento. Luego se comparan los resultados obtenidos con los reales para determinar la precisión o el error.

El rendimiento del clasificador se puede determinar a partir de la estimación del error con la fórmula:

$$Error[\%] = \left(\frac{\text{Número Datos Mal Clasificados}}{\text{Total Datos Validación}} \right) * 100 \quad (3.7)$$

3.8.1 Método de validación cruzada

Se estableció un conjunto de entrenamiento del 70 % de las señales y el restante 30% para realizar las pruebas con 30 repeticiones, garantizando que en las 30 pruebas se realizará el entrenamiento con la totalidad de la base de datos disponible.

3.8.2 Método de la Matriz de Confusión

Es una matriz en la cual los elementos de la diagonal principal representan el número de muestras identificadas apropiadamente por el clasificador, mientras que los otros elementos de la matriz corresponden al número de muestras mal clasificadas.

VN: Fracción de muestras negativas clasificadas apropiadamente, es decir, señales Normales.

FP: Fracción de muestras negativas clasificadas inapropiadamente, es decir, señaladas como señales con Soplo.

VP: Fracción de muestras positivas clasificadas apropiadamente, es decir, señales con Soplo.

FN: Fracción de muestras positivas clasificadas inapropiadamente, es decir, señaladas como señales Normales.

$$Precisión = \frac{VN + VP}{VN + FP + VP + FN} \quad (3.8)$$

$$Error = \frac{FN + FP}{VN + FP + VP + FN} \quad (3.9)$$

3.8.3 Media F_β

De acuerdo con la ecuación (3.13), la medida F_1 introducida por Van Rijsbergen para evaluar el rendimiento promedio en todas las categorías; se basa en un promedio del valor de la función F de cada categoría en proporción al número de muestras, es la media armónica de precisión (P) y recuperación (R), que combina la memoria y la precisión a partir de la siguiente fórmula (Z. Wang et al., 2007):

$$F_\beta = (1 + \beta^2) \frac{Precisión * Recuperación}{(\beta^2 * Precisión) + Recuperación}, \text{ con } \beta \in \mathcal{R} \text{ positivos} \quad (3.10)$$

$$R = \frac{\# \text{ Predicciones Correctas Positivas}}{\# \text{ Muestras Positivas}} \quad (3.11)$$

$$P = \frac{\# \text{ Predicciones Correctas Positivas}}{\# \text{ Predicciones Positivas}} \quad (3.12)$$

$$F_1 = \frac{2 * Precisión * Recuperación}{Precisión + Recuperación} \quad (3.13)$$

El primero parámetro (P) cuantifica el porcentaje de señales que están correctamente clasificados como positivos (que pertenecen a la categoría) y el segundo (R) cuantifica el porcentaje de señales positivas que se clasifican correctamente. Si β es igual a uno, se está dando la misma ponderación (o importancia) a Precisión que a la Recuperación, si β es mayor que uno de damos más importancia a Recuperación, mientras que si es menor que uno se le da más importancia a la Precisión.

3.8.4 Curvas ROC

La sensibilidad es la probabilidad de clasificar correctamente a un individuo cuyo estado real sea el definido como positivo respecto a la condición que estudia la prueba, razón por la que también es denominada fracción de verdaderos positivos. La especificidad es la probabilidad de clasificar correctamente a un individuo cuyo estado real sea el definido como negativo. Es igual al resultado de restar a uno la fracción de falsos positivos.

Un gráfico de curva ROC ilustra la sensibilidad y especificidad de cada uno de los posibles puntos de corte de un test diagnóstico cuya escala de medición es continua. La curva ROC se construye en base a la unión de distintos puntos de corte, correspondiendo a la sensibilidad (el eje Y) y 1-especificidad (el eje X) de cada uno de ellos. Ambos ejes incluyen valores entre 0 y 1 (0% a 100%). A modo de referencia, en todo gráfico de curva ROC se traza una línea desde el punto (0,0) al punto (1,1), llamada diagonal de referencia o línea de no-discriminación. El punto de corte de una escala continua que determina la sensibilidad y especificidad más alta es aquel que presenta el mayor índice de Youden, calculado según la fórmula (sensibilidad + especificidad - 1). Gráficamente, éste corresponde al punto de la curva ROC más cercano al ángulo superior-izquierdo del gráfico (punto 0,1). (Cerde & Cifuentes, 2012).

A partir de la estructura de la matriz de confusión (Tabla 3-2), se obtienen algunos parámetros estadísticos a partir de los cuales calculamos la precisión del clasificador a la hora de valorar las muestras para determinar a qué conjunto pertenecen (Normales o Soplos).

Tabla 3-2: Estructura de la matriz de confusión utilizada

		<i>Matriz de Confusión</i>			
		Normal	Soplo	Total Columna	Error de Comisión
Reales	Normal	VN	FP	VN + FP	FP/(VN + FP)
	Soplo	FN	VP	FN + VP	FN/(FN + VP)
	Total Fila	VN + FN	FP + VP	Total = VN + FP + FN + VP	
	Error de Omisión	FN/(VN + FN)	FP/(FP + VP)		Error = (Total - (VN + VP))/Total

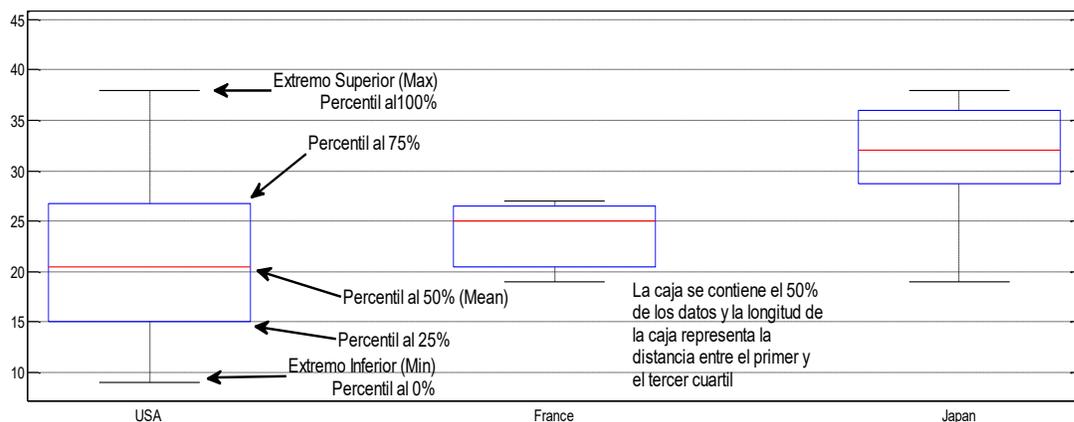
3.8.5 Diagrama de Bigotes

Este diagrama (Figura 3-16) tiene varios elementos gráficos (Nikolic-Doric et al., 2006):

- Las líneas más bajas y superiores de la "caja" son el 25 y 75 por ciento de la muestra. La distancia entre la tapa y fondo de la caja es el rango de intercuartile.
- La línea en el centro de la caja es el punto medio de la muestra. Si el punto medio no se centra en la caja, ésta es una indicación de la oblicuidad.
- Las "barbas" son líneas que extienden sobre y debajo de la caja. Demuestran el grado del resto de la muestra (a menos que hay afloramientos). No si se asume que en ningún afloramiento el máximo de la muestra es la tapa de la barba superior. El mínimo de la muestra es el fondo de la barba más baja. Por defecto, los datos que se encuentran por fuera de los bigotes son más de 1,5 veces la gama intercuartile que se encuentran fuera de los límites de la caja.
- El signo de más en la tapa del diagrama es una indicación de un afloramiento en los datos. Este punto pudo ser el resultado de un error de la entrada de datos, de una medida pobre, o de un cambio en el sistema que generó datos de forma errónea.

Las cortes en la caja son un intervalo gráfico de la confianza sobre el punto medio de una muestra. Los diagramas de la caja no tienen cortes por defecto. En un *boxplot* con cortes, dichos cortes representan un buen estimador de la incertidumbre, en la comparación de las medianas de cada caja graficada. Cuando los cortes no se traslapan indican que las medianas de los dos grupos difieren con un 5 por ciento de nivel de significancia.

Figura 3-16: Ejemplo de Diagrama de bigotes



Capítulo 4 – Resultados y Discusión

Se llevaron a cabo una serie de experimentos con los espacios de representación derivados de las características acústicas estimadas mediante los MFCC de las señales PCG a partir de los constructos resultantes de la aplicación de EMD / fastEMD / EEMD / CEEMAN / HVD, con los cuales se puso a prueba la capacidad discriminante de los clasificadores basados en redes bayesianas *Naïve Bayes* y en modelos ocultos de Markov (HMM), utilizados para la clasificación de señales PCG con soplos y normales. Adicionalmente, buscando mejorar el espacio de características de la señal, se tuvieron en cuenta 12 momentos estadísticos obtenidos con la aplicación de la transformada de *Hilbert Huang* a los constructos. Para incrementar el rendimiento de los clasificadores, se seleccionaron las características que proporcionaron una alta discernibilidad entre clases, aplicando los métodos de selección basado en los algoritmos *Fuzzy Rough Set* con entropía (FRS-E), Análisis de Componentes Principales (PCA) y *Sequential Forward Feature Selection* (SFFS).

Se realizó una subdivisión de la base de datos en *señales normales* y *señales con soplo*; entre las técnicas utilizadas para la descomposición de las señales tenemos el EMD, fastEMD, HVD, EEMD (EEMDv1: está fundamentada en la EMD y la EEMDv2: está fundamentada en la fastEMD), CEEMDAN (CEEMDANv1: está fundamentada en la EMD y la CEEMDANv2: está fundamentada en la fastEMD). El rendimiento de los clasificadores, se estableció mediante la validación cruzada 70-30 con 30 “*fold*”, de la cual se obtuvieron los datos para la curva ROC y el diagrama de bigotes.

En la Tabla 4-1, se puede apreciar la relación de tiempos de procesamiento y de recursos de memoria, demandados por cada una de las técnicas de descomposición utilizadas en las señales de la base de datos.

Tabla 4-1: Relación de tiempo de procesamiento y recursos de memoria con respecto a las técnicas de descomposición utilizadas

	Recursos de Memoria (MB)			Tiempo de Procesamiento (seg)		
	Min	Promedio	Max	Min	Promedio	Max
EMD - Normal	0,25	0,51	1,67	0,28	0,40	0,61
EMD - Soplo	0,01	0,51	2,01	0,24	0,36	0,63
fastEMD - Normal	0,25	0,75	2,87	0,15	0,57	0,72
fastEMD - Soplo	0,32	0,83	1,99	0,15	0,60	0,75
HVD - Normal	0,43	0,58	2,21	7,18	9,18	295,43
HVD - Soplo	0,50	0,60	1,00	7,31	7,75	8,27
EEMDv1 - Normal	0,36	0,64	3,39	18,26	23,66	41,19
EEMDv1Soplo	0,25	0,61	5,05	18,60	24,32	41,743
EEMDv2 - Normal	0,00	0,73	7,13	28,62	62,67	125,43
EEMDv2 - Soplo	0,46	0,76	10,17	23,17	44,69	121,56
CEEMDANv1 - Normal	0,01	0,57	7,56	87,13	122,97	189,32
CEEMDANv1 - Soplo	0,01	0,54	1,93	90,49	121,97	213,01
CEEMDANv2 - Normal	0,43	0,53	1,01	166,13	220,54	337,90
CEEMDANv2 - Soplo	0,50	0,60	1,14	131,68	177,34	263,36

En la Tabla 4-2, muestra el promedio del error cuadrático medio obtenido al comparar la señal original con el constructor, en la segunda columna de la tabla se calcula sin tener en cuenta la señal residual y en la tercera columna teniendo en cuenta la señal residual.

Tabla 4-2: Error cuadrático medio en la reconstrucción de la señal original

	<i>Error sin señal residual (1.0e-3)</i>	<i>Error con señal residual (1.0e-8)</i>
EMD – Normal	0.03	0.32
EMD – Soplo	3.82	0.53
fastEMD – Normal	0.15	0.32
fastEMD – Soplo	0.33	0.53
EEMDv1 – Normal	0.01	564.98
EEMDv1Soplo	0.01	945.20
EEMDv2 – Normal	0.08	563.97
EEMDv2 – Soplo	0.15	946.41
CEEMDANv1 – Normal	0.02	0.32
CEEMDANv1 – Soplo	0.74	0.53
CEEMDANv2 – Normal	0.17	0.32
CEEMDANv2 – Soplo	0.41	0.53

4.1 Espacio de Representación

Con respecto al **primer objetivo específico**, se generaron constructos a partir de diferentes técnicas de descomposición de señales, luego de los constructos se estableció la matriz de características y la reducción de las mismas a partir del PCA, FRS y SFFS paralelamente (ver Tabla A-6 a Tabla A-10). Se recomienda dirigirse al anexo A para ampliar la información referente a los análisis de relevancia realizados durante las diferentes pruebas.

Finalmente se entrenaron los diferentes clasificadores implementados (Tabla B-11 a la Tabla B-13) y con los resultados obtenidos de la validación cruzada se identificó el grupo de características que presentaban más ocurrencia en los diferentes análisis de relevancia para generar con estas un espacio de representación (ver Figura 4-5). Se recomienda dirigirse al anexo B para ampliar la información referente a al entrenamiento y validación de los diferentes clasificadores utilizados durante las pruebas.

En las Tabla 4-3 y Tabla 4-4 se evidencia el desempeño registrado con los diferentes clasificadores, donde se hace notoria la necesidad de utilizar conjuntamente los momentos estadísticos como los coeficientes MFCC (ver Figura 4-1 a la Figura 4-3), ya que estos por si solos no proporcionan una buena precisión con el HMM (ver Figura 4-1).

Tabla 4-3: Resultados de los clasificadores entrenados con los 60 coeficientes del MFCC convencional

Técnica de Descomposición	Clasificador -> Promedio \pm Desviación Estándar (Varianza)		
	HMM	NaiveBayes	KNN
HVD	74.17 \pm 13.37	96.11 \pm 6.83	94.72 \pm 7.42
	(1.79)	(0.47)	(0.55)
EMDv3	73.61 \pm 11.18	95.83 \pm 6.83	93.61 \pm 6.45
	(1.25)	(0.47)	(0.42)
fastEMD	75.83 \pm 15.98	93.61 \pm 6.45	95.56 \pm 5.24
	(2.56)	(0.42)	(0.27)
EEMDv2	77.22 \pm 13.30	96.39 \pm 5.66	97.22 \pm 5.05
	(1.77)	(0.32)	(0.26)
EEMDv1	80.56 \pm 13.55	94.72 \pm 8.04	93.89 \pm 8.74
	(1.84)	(0.65)	(0.76)

<i>CEEMDANv1</i>	80.28 ± 11.88 (1.41)	91.94 ± 9.90 (0.98)	92.22 ± 7.87 (0.62)
<i>CEEMDANv2</i>	79.17 ± 15.59 (2.43)	95.56 ± 5.24 (0.27)	95.00 ± 5.62 (0.32)
Normalización señal: unipolar, Normalización de la matriz de características: unipolar			
	HMM	NaiveBayes	KNN
<i>HVD</i>	61.74 ± 15.90 (2.53)	72.78 ± 23.34 (5.45)	72.29 ± 22.92 (5.25)
<i>EMDv3</i>	62.22 ± 15.28 (2.33)	72.99 ± 23.50 (5.52)	71.81 ± 22.41 (5.02)
<i>fastEMD</i>	61.46 ± 15.51 (2.41)	71.81 ± 22.33 (4.99)	72.78 ± 23.21 (5.39)
<i>EEMDv2</i>	65.21 ± 17.67 (3.12)	73.19 ± 23.62 (5.58)	73.68 ± 24.04 (5.78)
<i>EEMDv1</i>	65.14 ± 17.69 (3.13)	72.08 ± 22.83 (5.21)	71.74 ± 22.54 (5.08)
<i>CEEMDANv1</i>	65.07 ± 17.19 (2.96)	70.83 ± 21.88 (4.79)	71.18 ± 21.95 (4.82)
<i>CEEMDANv2</i>	63.47 ± 17.16 (2.94)	72.78 ± 23.29 (5.42)	72.36 ± 22.87 (5.23)

Tabla 4-4: Resultados de los clasificadores entrenados con los 12 momentos estadísticos

Técnica de Descomposición	Clasificador -> Promedio ± Desviación Estándar (Varianza)		
	HMM	NaiveBayes	KNN
Normalización señal: bipolar, Normalización de la matriz de características: unipolar			
<i>HVD</i>	74.72 ± 14.92 (2.23)	83.33 ± 10.72 (1.15)	91.67 ± 8.75 (0.77)
<i>EMDv3</i>	63.06 ± 14.13 (2.00)	78.61 ± 13.07 (1.71)	78.89 ± 12.33 (1.52)
<i>fastEMD</i>	83.33 ± 12.38 (1.53)	89.44 ± 7.56 (0.57)	87.78 ± 8.40 (0.71)
<i>EEMDv2</i>	88.33 ± 9.93 (0.99)	92.22 ± 6.90 (0.48)	93.33 ± 5.95 (0.35)
<i>EEMDv1</i>	63.89 ± 12.82 (1.64)	74.17 ± 11.86 (1.41)	74.72 ± 12.66 (1.60)
<i>CEEMDANv1</i>	62.78 ± 14.14 (2.00)	71.11 ± 13.44 (1.81)	74.72 ± 15.24 (2.32)
<i>CEEMDANv2</i>	90.28 ± 8.50 (0.72)	91.94 ± 7.09 (0.50)	95.83 ± 5.69 (0.32)
Normalización señal: unipolar, Normalización de la matriz de características: unipolar			
	HMM	NaiveBayes	KNN

<i>HVD</i>	62.08 ± 15.91 (2.53)	67.01 ± 18.69 (3.49)	70.83 ± 21.61 (4.67)
<i>EMDv3</i>	57.29 ± 12.49 (1.56)	64.24 ± 16.82 (2.83)	64.38 ± 16.70 (2.79)
<i>fastEMD</i>	67.15 ± 19.15 (3.67)	69.86 ± 20.73 (4.30)	68.89 ± 19.94 (3.98)
<i>EEMDv2</i>	68.33 ± 20.29 (4.12)	70.97 ± 21.63 (4.68)	71.81 ± 22.28 (4.96)
<i>EEMDv1</i>	56.81 ± 11.38 (1.30)	62.36 ± 15.12 (2.29)	62.50 ± 15.16 (2.30)
<i>CEEMDANv1</i>	56.67 ± 11.51 (1.33)	60.62 ± 13.62 (1.86)	62.08 ± 14.85 (2.20)
<i>CEEMDANv2</i>	68.54 ± 20.37 (4.15)	71.04 ± 21.85 (4.77)	73.13 ± 23.48 (5.51)

Figura 4-1: Precisión lograda con el clasificados HMM a partir de cada sub-grupo de características utilizadas

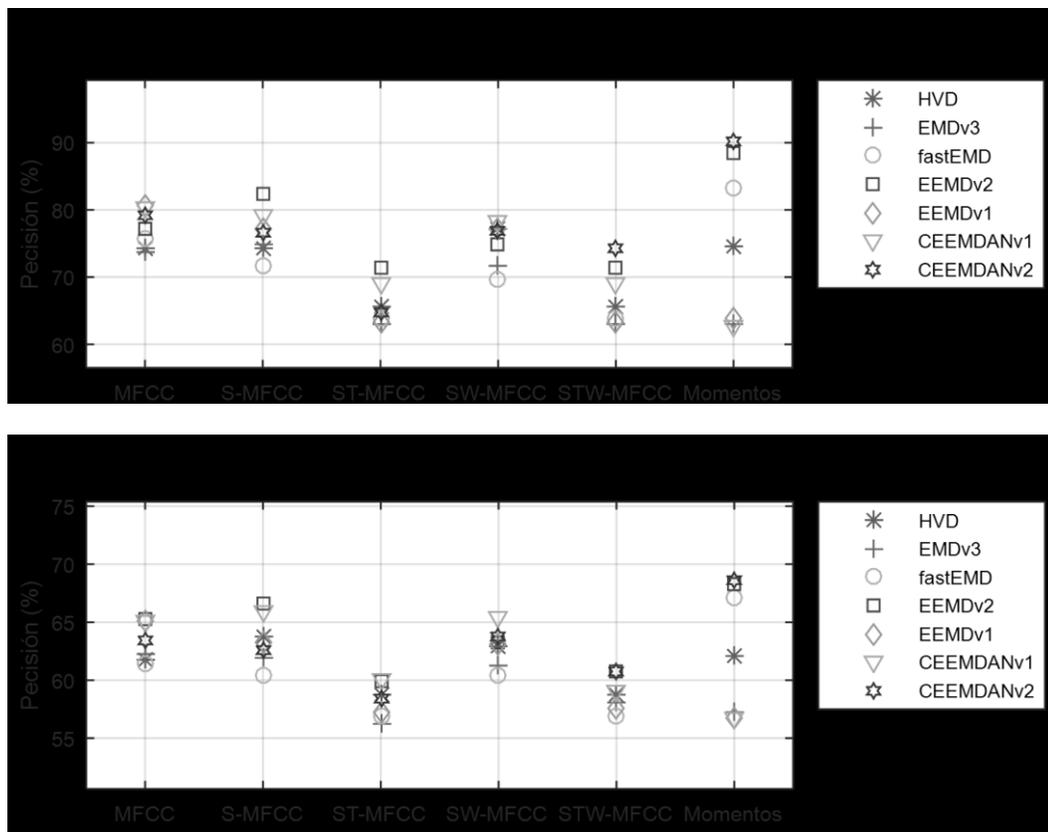


Figura 4-2: Precisión lograda con el clasificados Naive Bayes a partir de cada sub-grupo de características utilizadas

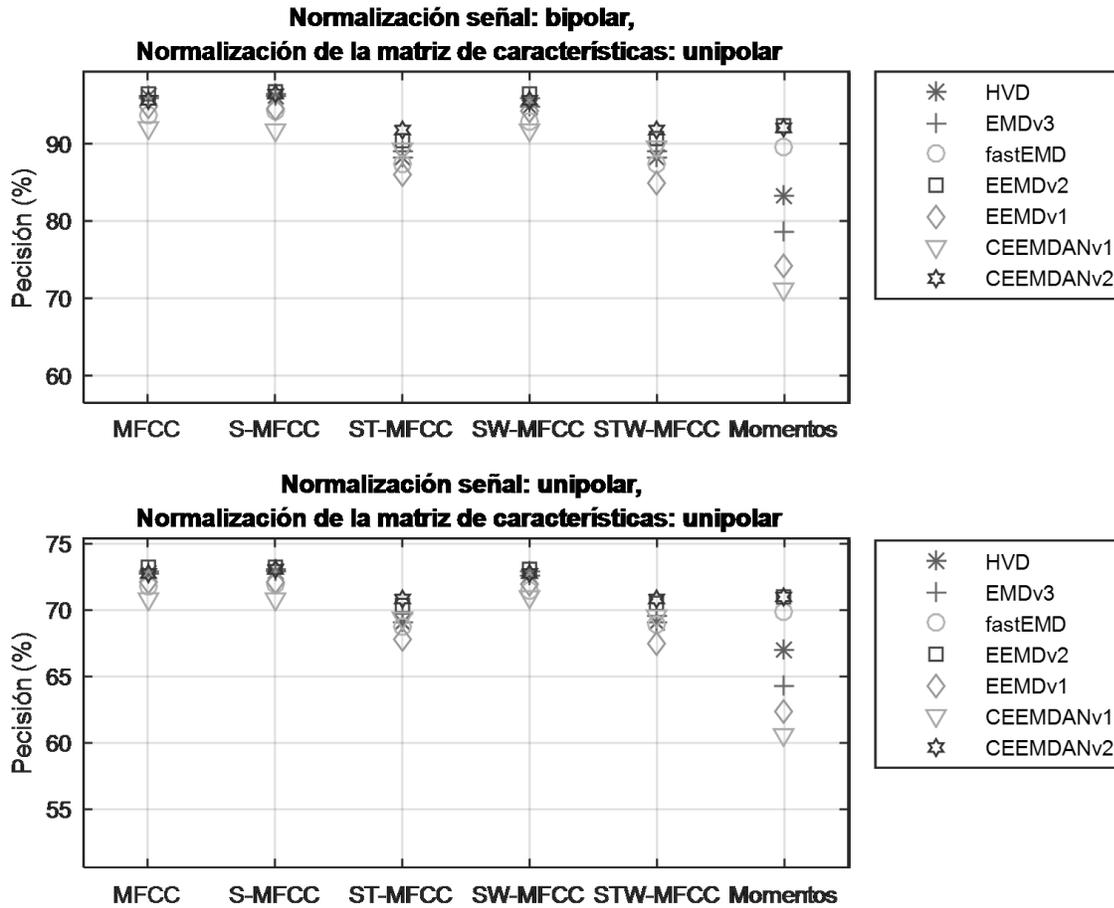
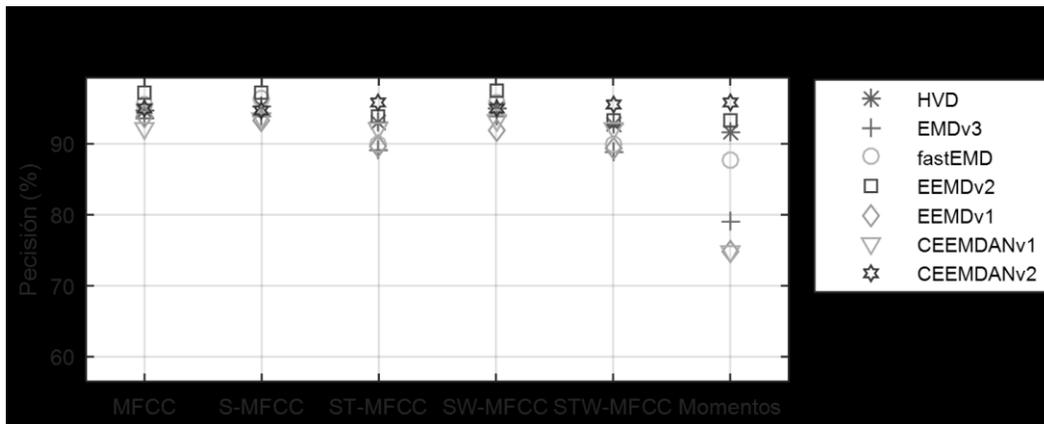
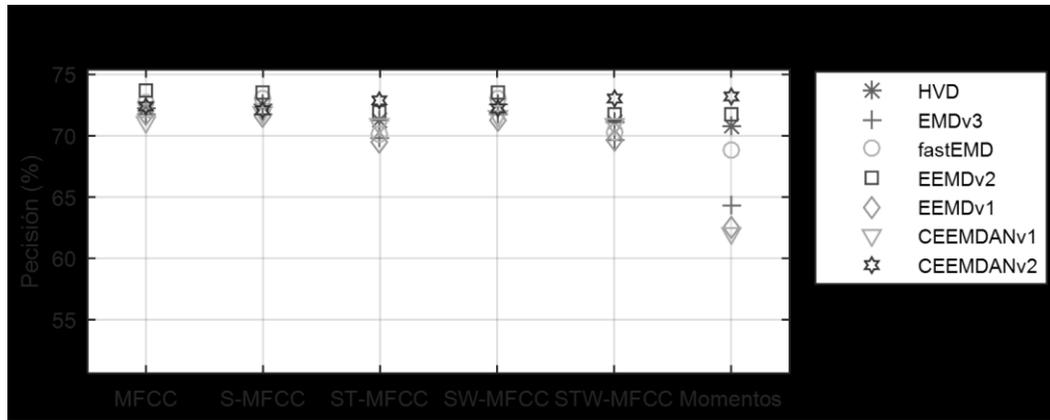


Figura 4-3: Precisión lograda con el clasificados KNN a partir de cada sub-grupo de características utilizadas





En la Tabla 4-5 se puede observar el resumen de los mejores resultados obtenidos con los clasificadores a partir de cada uno de los análisis de relevancia en el conjunto de señales seleccionadas. El mejor resultado se generó con la descomposición CEEMDANv2 a partir del análisis de relevancia FRS con una precisión de 97.78 % con una desviación estándar del 1.16% y una varianza de 0.01.

Tabla 4-5: Resumen de los mejores resultados promedios, obtenidos con los clasificadores a partir de los análisis de relevancia

Técnica de Descomposición	Análisis de Relevancia			Clasificador -> Promedio ± Desviación Estándar (Varianza)			
	Normalización señal: bipolar, Normalización de la matriz de características: unipolar						
	PCA	FRS	SFFS	HMM	Naive Bayes	KNN	PSOHMM
HVD	No	No	Si	96.69 ± 1.72 (0.03)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
HVD	No	No	Si	96.69 ± 1.72 (0.03)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
EMDv3	No	No	Si	95.81 ± 1.94 (0.04)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
fastEMD	No	No	Si	97.22 ± 1.46 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
EEMDv2	No	Si	No	96.92 ± 1.60 (0.03)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
EEMDv2	No	No	Si	97.08 ± 1.41 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
CEEMDANv2	No	Si	No	97.78 ± 1.16 (0.01)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
CEEMDANv2	No	No	Si	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
Normalización señal: unipolar, Normalización de la matriz de características: unipolar							
	PCA	FRS	SFFS	HMM	Naive Bayes	KNN	PSOHMM

HVD	No	Si	No	95.33 ± 1.60 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
HVD	No	No	Si	96.36 ± 1.19 (0.01)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
EMDv3	No	No	Si	95.31 ± 1.91 (0.04)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
fastEMD	No	Si	No	95.08 ± 1.42 (0.02)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
fastEMD	No	No	Si	96.08 ± 1.87 (0.04)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
EEMDv2	No	Si	No	94.06 ± 12.04 (1.45)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
EEMDv2	No	No	Si	97.44 ± 1.42 (0.02)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
CEEMDANv2	No	Si	No	97.56 ± 1.09 (0.01)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
CEEMDANv2	No	No	Si	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)

Una vez identificadas las características (índices {[14], [305], [311], [312]}) que proporcionaron la precisión más alta en la validación de los resultados, se entrenan los clasificadores con estas obteniendo valores muy inferiores a los esperados con el HMM (ver Tabla 4-6).

Tabla 4-6: Validación clasificadores con las características que más precisión mostraron en las pruebas iniciales

Técnica de Descomposición	Clasificador -> Promedio ± Desviación Estándar (Varianza)		
	Naive Bayes	KNN	HMM
	Normalización señal: bipolar, Normalización de la matriz de características: unipolar		
<i>HVD</i>	94.44 ± 5.51 (0.30)	80.00 ± 10.40 (1.08)	81.11 ± 12.17 (1.48)
<i>EMDv3</i>	89.17 ± 8.79 (0.77)	76.94 ± 9.95 (0.99)	66.39 ± 16.15 (2.61)
<i>fastEMD</i>	96.11 ± 4.23 (0.18)	74.17 ± 10.11 (1.02)	81.67 ± 12.46 (1.55)
<i>EEMDv2</i>	97.78 ± 3.75 (0.14)	74.17 ± 12.45 (1.55)	50.00 ± 0.00 (0.00)
<i>EEMDv1</i>	81.67 ± 12.84 (1.65)	68.61 ± 15.88 (2.52)	63.89 ± 14.57 (2.12)
<i>CEEMDANv1</i>	87.78 ± 10.20 (1.04)	79.17 ± 13.45 (1.81)	76.39 ± 16.24 (2.64)
<i>CEEMDANv2</i>	97.50 ± 3.88 (0.15)	82.22 ± 9.47 (0.90)	86.67 ± 11.91 (1.42)
	Normalización señal: unipolar, Normalización de la matriz de características: unipolar		
	Naive Bayes	KNN	HMM
<i>HVD</i>	72.15 ± 22.62 (5.12)	64.79 ± 16.72 (2.79)	65.63 ± 18.13 (3.29)
<i>EMDv3</i>	69.38 ± 20.47 (4.19)	63.26 ± 15.34 (2.35)	60.00 ± 14.95 (2.24)
<i>fastEMD</i>	73.13 ± 23.41 (5.48)	61.94 ± 14.36 (2.06)	65.97 ± 18.45 (3.40)
<i>EEMDv2</i>	74.03 ± 24.28 (5.90)	62.08 ± 15.00 (2.25)	60.14 ± 18.12 (3.28)

<i>EEMDv1</i>	65.83 ± 18.06 (3.26)	59.37 ± 14.03 (1.97)	56.53 ± 12.75 (1.62)
<i>CEEMDANv1</i>	69.10 ± 20.37 (4.15)	64.79 ± 17.33 (3.00)	63.13 ± 16.69 (2.79)
<i>CEEMDANv2</i>	73.82 ± 24.09 (5.80)	66.46 ± 17.90 (3.20)	68.47 ± 20.56 (4.23)

En vista de los resultados inferiores a los esperados se procede a redefinir el conjunto de características seleccionadas para el entrenamiento de los clasificadores, a partir de un análisis estadístico de los mejores resultados obtenidos en los experimentos previos. En la Figura 4-4 se muestra en diagrama de frecuencia con los índices de las características que presentaron los mejores resultados en la validación de los clasificadores y a partir de estas se realizó el análisis de relevancia SFFS arrojando las 25 características: {[5], [12], [14], [27], [32], [38], [43], [51], [57], [125], [133],[147],[150],[154], [193], [195], [205], [242], [244], [261], [295], [301], [303], [305], [311]}, las cuales se resaltan en el gráfico con marcas.

Figura 4-4: Diagrama de frecuencia de las características que proporcionaron mejores resultados en el entrenamiento de los clasificadores

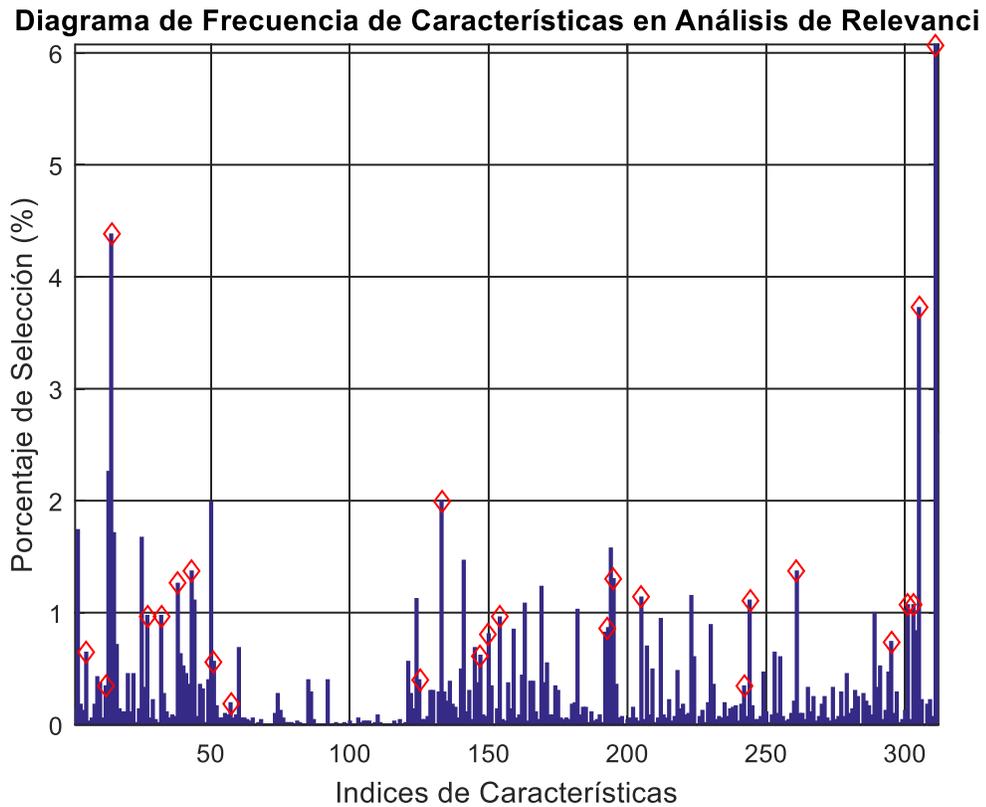


Tabla 4-7: Listado de índices de características agrupadas por porcentaje de ocurrencia de acuerdo a las tasas de acierto más altas

Ocurrencia (%)	Índices de Características
0.0 ==	[66],[69],[70],[71],[72],[80],[83],[84],[88],[89],[90],[91],[93],[94],[96],[97],[99],[101],[102],[108],[112],[113],[114],[115],[117],[119],[131],[152],[199],[225],[284],[307]
0.5 >=	[2],[5],[13],[14],[15],[16],[25],[27],[32],[38],[39],[40],[43],[44],[50],[51],[60],[121],[124],[133],[141],[145],[147],[150],[154],[159],[163],[169],[171],[182],[192],[193],[194],[195],[205],[207],[212],[223],[224],[230],[244],[253],[255],[261],[289],[291],[295],[301],[303],[304],[305],[311],[312]
1.0 >=	[2],[13],[14],[15],[25],[38],[43],[44],[50],[124],[133],[141],[163],[169],[182],[194],[195],[205],[223],[244],[261],[301],[303],[305],[311],[312]
1.5 >=	[2],[13],[14],[15],[25],[50],[133],[194],[305],[311],[312]
2.0 >=	[13],[14],[305],[311],[312]
2.5 >=	[14],[305],[311],[312]
3.0 >=	[14],[305],[311]
4.0 >=	[14],[311]
4.5 >=	[311]

Podemos apreciar que no necesariamente las características con más ocurrencia en los diferentes análisis de relevancia son las que van a conformar el conjunto de características seleccionado.

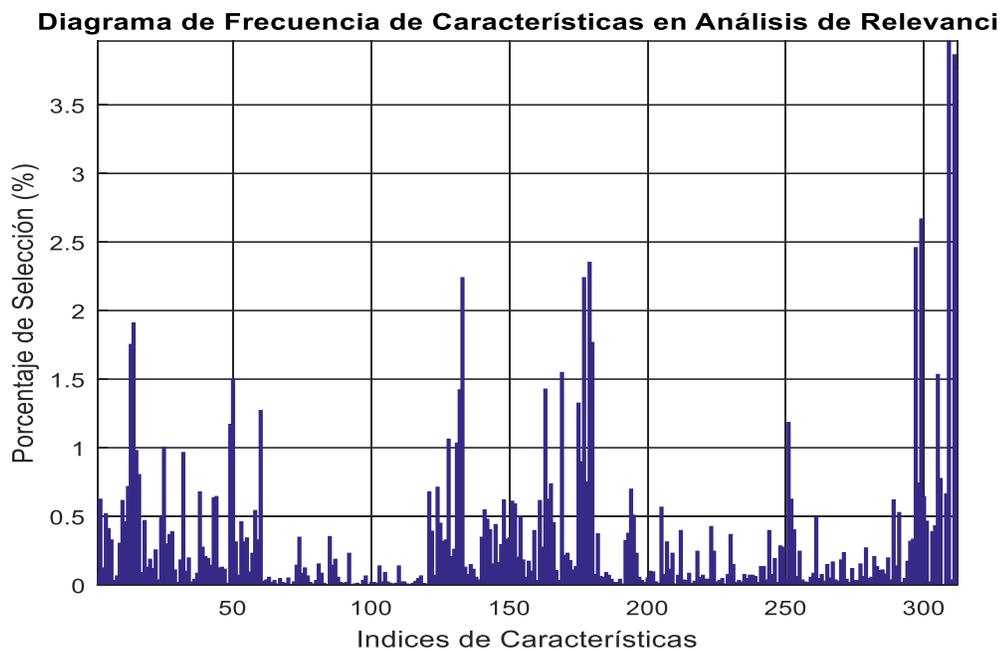
Tabla 4-8: Resumen de los mejores resultados promedios, obtenidos con los clasificadores a partir del conjunto de 25 características

Técnica de Descomposición	Clasificador -> Promedio \pm Desviación Estándar (Varianza)		
	Normalización señal: bipolar, Normalización de la matriz de características: unipolar		
	Naive Bayes	KNN	HMM
HVD	97.22 \pm 4.00 (0.16)	95.28 \pm 6.07 (0.37)	87.22 \pm 9.96 (0.99)
EMDv3	93.33 \pm 6.71 (0.45)	93.33 \pm 8.59 (0.74)	81.67 \pm 10.59 (1.12)
fastEMD	91.11 \pm 6.90 (0.48)	94.72 \pm 6.37 (0.41)	89.17 \pm 10.53 (1.11)
EEMDv2	97.50 \pm 4.97 (0.25)	96.94 \pm 5.12 (0.26)	88.61 \pm 9.66 (0.93)
EEMDv1	90.83 \pm 10.35 (1.07)	92.50 \pm 7.37 (0.54)	75.56 \pm 11.57 (1.34)
CEEMDANv1	91.94 \pm 9.66 (0.93)	91.39 \pm 7.73 (0.60)	83.33 \pm 9.28 (0.86)
CEEMDANv2	96.11 \pm 7.50 (0.56)	97.22 \pm 5.05 (0.26)	85.56 \pm 9.01 (0.81)
	Normalización señal: unipolar, Normalización de la matriz de características: unipolar		
	Naive Bayes	KNN	HMM
HVD	73.61 \pm 23.92 (5.72)	72.85 \pm 23.31 (5.43)	68.40 \pm 20.21 (4.08)
EMDv3	71.88 \pm 22.51 (5.07)	71.46 \pm 22.29 (4.97)	65.83 \pm 17.27 (2.98)
fastEMD	70.76 \pm 21.47 (4.61)	72.08 \pm 22.65 (5.13)	68.61 \pm 20.15 (4.06)
EEMDv2	73.82 \pm 24.14 (5.83)	73.61 \pm 23.97 (5.75)	69.93 \pm 20.98 (4.40)
EEMDv1	70.35 \pm 21.71 (4.71)	71.18 \pm 21.95 (4.82)	63.26 \pm 15.56 (2.42)
CEEMDANv1	71.18 \pm 22.16 (4.91)	70.69 \pm 21.47 (4.61)	66.67 \pm 18.08 (3.27)

CEEMDANv2 73.12 ± 23.75 (5.64) 73.54 ± 23.88 (5.70) 68.89 ± 20.23 (4.09)

En la Figura 4-5 se puede apreciar un gráfico de barras donde se relaciona la frecuencia de selección de las 312 características que componen la matriz de características en los análisis de relevancia realizados simultáneamente durante las pruebas iniciales, teniendo en cuenta todos los resultados y no solo los más relevantes.

Figura 4-5: Gráfico de diagrama de frecuencias de las características en los análisis de relevancia



En la Tabla 4-9 se hace referencia a las características que no se hicieron presentes en ninguno de los análisis de relevancia y de aquellas características que obtuvieron mayor ocurrencia de acuerdo a los niveles referenciados en el eje de las ordenadas, de acuerdo al gráfico de barras. Se utilizaron simultáneamente las tres técnicas de análisis de relevancia, luego se realizó un análisis estadístico para determinar cuáles eran las características con más ocurrencia en referencia a todas las pruebas realizadas, y en base a esta información se realizó una tabla de frecuencias las cuales se filtraron para identificar las características que más hacían presencia en los análisis.

Tabla 4-9: Listado de índices de características agrupadas por ocurrencia

Ocurrencia (%)	Índices de Características
0.0 ==	[71],[84],[93],[96],[99],[114],[307]
0.5 >=	[2],[4],[10],[12],[13],[14],[15],[16],[18],[24],[25],[32],[38],[43],[44],[49],[50],[58],[60],[121],[124],[128],[131],[132],[133],[141],[142],[148],[151],[152],[154],[161],[163],[164],[165],[169],[175],[177],[179],[180],[194],[195],[205],[251],[252],[261],[289],[291],[297],[299],[300],[301],[305],[306],[308],[309],[311],[312]
1.0 >=	[13],[14],[25],[49],[50],[60],[128],[131],[132],[133],[163],[169],[175],[177],[179],[180],[251],[297],[299],[305],[309],[311],[312]
1.5 >=	[13],[14],[133],[169],[177],[179],[180],[297],[299],[305],[309],[311],[312]
2.0 >=	[14],[133],[309],[311],[312]
2.5 >=	[309],[311],[312]
4.0 >=	[309]

En las Tabla 4-10 a la Tabla 4-13, se muestran los resultados obtenidos a partir de diferentes conjuntos de características utilizados en el entrenamiento y validación de los clasificadores HMM, Naive Bayes y KNN, buscando establecer el conjunto que permita clasificar con más precisión el conjunto de señales.

Tabla 4-10: Resumen de los resultados promedios obtenidos con los clasificadores a partir del conjunto de 3 características (ver Tabla 4-9 umbral $2.5 \geq$)

Técnica de Descomposición	Clasificador -> Promedio \pm Desviación Estándar (Varianza)		
	Normalización señal: bipolar, Normalización de la matriz de características: unipolar		
	HMM	Naive Bayes	KNN
<i>HVD</i>	85.83 \pm 12.41 (1.54)	88.33 \pm 10.85 (1.18)	79.44 \pm 10.88 (1.18)
<i>EMDv3</i>	64.72 \pm 18.00 (3.24)	77.22 \pm 10.93 (1.19)	72.50 \pm 10.30 (1.06)
<i>fastEMD</i>	83.06 \pm 12.28 (1.51)	92.22 \pm 6.90 (0.48)	69.17 \pm 12.41 (1.54)
<i>EEMDv2</i>	89.72 \pm 11.51 (1.33)	95.56 \pm 5.24 (0.27)	65.28 \pm 13.51 (1.82)
<i>EEMDv1</i>	69.72 \pm 10.83 (1.17)	70.83 \pm 12.90 (1.66)	60.56 \pm 16.37 (2.68)
<i>CEEMDANv1</i>	66.94 \pm 13.92 (1.94)	73.61 \pm 14.36 (2.06)	68.33 \pm 11.03 (1.22)
<i>CEEMDANv2</i>	90.56 \pm 10.66 (1.14)	95.00 \pm 5.62 (0.32)	77.78 \pm 11.01 (1.21)
Técnica de Descomposición	Normalización señal: unipolar, Normalización de la matriz de características: unipolar		
	HMM	Naive Bayes	KNN
	<i>HVD</i>	68.06 \pm 19.78 (3.91)	69.10 \pm 20.37 (4.15)
<i>EMDv3</i>	56.11 \pm 13.44 (1.81)	64.10 \pm 16.05 (2.58)	61.60 \pm 14.38 (2.07)
<i>fastEMD</i>	67.08 \pm 19.11 (3.65)	71.18 \pm 21.85 (4.77)	59.17 \pm 12.80 (1.64)
<i>EEMDv2</i>	70.28 \pm 21.92 (4.81)	72.64 \pm 23.10 (5.34)	58.06 \pm 13.18 (1.74)
<i>EEMDv1</i>	59.65 \pm 12.78 (1.63)	60.76 \pm 14.35 (2.06)	55.69 \pm 12.51 (1.56)
<i>CEEMDANv1</i>	58.06 \pm 13.27 (1.76)	61.74 \pm 14.87 (2.21)	59.38 \pm 12.34 (1.52)
<i>CEEMDANv2</i>	70.35 \pm 21.68 (4.70)	72.29 \pm 22.79 (5.20)	63.82 \pm 15.67 (2.46)

Tabla 4-11: Resumen de los resultados promedios obtenidos con los clasificadores a partir del conjunto de 4 características

Técnica de Descomposición	Clasificador -> Promedio ± Desviación Estándar (Varianza)			
	Normalización señal: bipolar, Normalización de la matriz de características: unipolar			
	HMM	Naive Bayes	KNN	PSOHMM
<i>HVD</i>	50.00 ± 0.00 (0.00)	94.06 ± 2.04 (0.04)	79.86 ± 2.86 (0.08)	50.00 ± 0.00 (0.00)
<i>EMDv3</i>	50.00 ± 0.00 (0.00)	87.78 ± 2.68 (0.07)	76.78 ± 3.31 (0.11)	50.00 ± 0.00 (0.00)
<i>fastEMD</i>	50.00 ± 0.00 (0.00)	95.28 ± 1.66 (0.03)	73.72 ± 2.37 (0.06)	50.00 ± 0.00 (0.00)
<i>EEMDv2</i>	50.00 ± 0.00 (0.00)	97.83 ± 1.11 (0.01)	76.64 ± 3.49 (0.12)	50.00 ± 0.00 (0.00)
<i>EEMDv1</i>	50.00 ± 0.00 (0.00)	81.33 ± 3.24 (0.11)	70.89 ± 2.83 (0.08)	50.00 ± 0.00 (0.00)
<i>CEEMDANv1</i>	87.50 ± 3.02 (0.09)	87.06 ± 2.51 (0.06)	79.06 ± 3.55 (0.13)	50.00 ± 0.00 (0.00)
<i>CEEMDANv2</i>	97.44 ± 1.33 (0.02)	97.03 ± 1.54 (0.02)	83.75 ± 2.56 (0.07)	50.00 ± 0.00 (0.00)
Técnica de Descomposición	Normalización señal: unipolar, Normalización de la matriz de características: unipolar			
	HMM	Naive Bayes	KNN	PSOHMM
	<i>HVD</i>	82.60 ± 19.04 (3.63)	93.99 ± 1.84 (0.03)	85.07 ± 5.50 (0.30)
<i>EMDv3</i>	77.90 ± 16.35 (2.67)	88.53 ± 2.53 (0.06)	75.33 ± 3.55 (0.13)	62.02 ± 15.34 (2.35)
<i>fastEMD</i>	82.56 ± 18.99 (3.61)	95.22 ± 1.55 (0.02)	80.65 ± 7.51 (0.56)	66.24 ± 18.45 (3.41)
<i>EEMDv2</i>	84.62 ± 20.14 (4.06)	97.79 ± 1.21 (0.01)	82.58 ± 6.20 (0.38)	67.21 ± 19.04 (3.63)
<i>EEMDv1</i>	71.67 ± 13.28 (1.76)	81.69 ± 3.29 (0.11)	71.58 ± 3.61 (0.13)	58.80 ± 10.93 (1.19)
<i>CEEMDANv1</i>	85.66 ± 3.43 (0.12)	87.69 ± 2.52 (0.06)	77.74 ± 3.56 (0.13)	61.56 ± 14.53 (2.11)
<i>CEEMDANv2</i>	96.94 ± 1.49 (0.02)	97.19 ± 1.36 (0.02)	89.09 ± 5.60 (0.31)	69.83 ± 20.77 (4.31)

Tabla 4-12: Resumen de los resultados promedios obtenidos con los clasificadores a partir del conjunto de 5 características (ver Tabla 4-9 umbral 2.0 ≥)

Técnica de Descomposición	Clasificador -> Promedio ± Desviación Estándar (Varianza)		
	Normalización señal: bipolar, Normalización de la matriz de características: unipolar		
	HMM	Naive Bayes	KNN
<i>HVD</i>	86.11 ± 12.82 (1.64)	92.22 ± 8.74 (0.76)	88.06 ± 8.94 (0.80)
<i>EMDv3</i>	73.61 ± 12.20 (1.49)	89.72 ± 9.46 (0.89)	76.39 ± 12.96 (1.68)
<i>fastEMD</i>	90.56 ± 8.11 (0.66)	94.44 ± 7.37 (0.54)	74.17 ± 12.83 (1.65)
<i>EEMDv2</i>	96.11 ± 5.68 (0.32)	97.78 ± 4.34 (0.19)	86.11 ± 10.57 (1.12)
<i>EEMDv1</i>	66.11 ± 14.99 (2.25)	75.56 ± 15.31 (2.34)	75.00 ± 12.18 (1.48)
<i>CEEMDANv1</i>	83.89 ± 12.17 (1.48)	86.39 ± 10.83 (1.17)	80.28 ± 11.26 (1.27)
<i>CEEMDANv2</i>	92.50 ± 8.85 (0.78)	96.39 ± 6.45 (0.42)	88.33 ± 8.64 (0.75)
Técnica de Descomposición	Normalización señal: unipolar, Normalización de la matriz de características: unipolar		
	HMM	Naive Bayes	KNN
	<i>HVD</i>	69.10 ± 20.74 (4.30)	70.97 ± 21.74 (4.73)
<i>EMDv3</i>	62.29 ± 15.16 (2.30)	70.00 ± 21.13 (4.46)	62.99 ± 15.69 (2.46)

<i>fastEMD</i>	70.28 ± 21.19 (4.49)	72.08 ± 22.68 (5.14)	62.15 ± 15.39 (2.37)
<i>EEMDv2</i>	72.43 ± 23.01 (5.30)	73.68 ± 23.96 (5.74)	68.26 ± 19.63 (3.85)
<i>EEMDv1</i>	57.85 ± 12.52 (1.57)	62.50 ± 15.77 (2.49)	62.08 ± 15.04 (2.26)
<i>CEEMDANv1</i>	65.35 ± 18.14 (3.29)	67.99 ± 19.51 (3.80)	65.00 ± 17.10 (2.92)
<i>CEEMDANv2</i>	71.25 ± 22.11 (4.89)	73.19 ± 23.65 (5.59)	68.89 ± 20.12 (4.05)

Tabla 4-13: Resumen de los resultados promedios obtenidos con los clasificadores a partir del conjunto de 13 características (ver Tabla 4-9 umbral $1.5 \geq$)

Técnica de Descomposición	Clasificador -> Promedio ± Desviación Estándar (Varianza)			
	Normalización señal: bipolar, Normalización de la matriz de características: unipolar			
	HMM	Naive Bayes	KNN	PSOHMM
<i>HVD</i>	94.44 ± 1.55 (0.02)	94.22 ± 1.92 (0.04)	90.28 ± 2.10 (0.04)	88.47 ± 8.22 (0.68)
<i>EMDv3</i>	93.14 ± 2.08 (0.04)	94.33 ± 1.49 (0.02)	86.22 ± 2.04 (0.04)	85.75 ± 5.46 (0.30)
<i>fastEMD</i>	93.94 ± 2.18 (0.05)	95.25 ± 1.57 (0.02)	81.94 ± 2.87 (0.08)	89.06 ± 3.59 (0.13)
<i>EEMDv2</i>	97.25 ± 1.50 (0.02)	98.00 ± 0.99 (0.01)	91.94 ± 2.41 (0.06)	94.56 ± 2.39 (0.06)
<i>EEMDv1</i>	87.92 ± 2.90 (0.08)	84.92 ± 2.73 (0.07)	81.78 ± 2.79 (0.08)	75.19 ± 8.74 (0.76)
<i>CEEMDANv1</i>	88.56 ± 2.50 (0.06)	88.89 ± 2.14 (0.05)	85.19 ± 2.60 (0.07)	81.94 ± 9.15 (0.84)
<i>CEEMDANv2</i>	96.08 ± 1.64 (0.03)	97.22 ± 1.74 (0.03)	94.28 ± 2.16 (0.05)	92.31 ± 3.71 (0.14)
Normalización señal: unipolar, Normalización de la matriz de características: unipolar				
	HMM	Naive Bayes	KNN	PSOHMM
<i>HVD</i>	94.44 ± 1.55 (0.02)	94.22 ± 1.92 (0.04)	90.28 ± 2.10 (0.04)	88.47 ± 8.22 (0.68)
<i>EMDv3</i>	93.14 ± 2.08 (0.04)	94.33 ± 1.49 (0.02)	86.22 ± 2.04 (0.04)	85.75 ± 5.46 (0.30)
<i>fastEMD</i>	93.94 ± 2.18 (0.05)	95.25 ± 1.57 (0.02)	81.94 ± 2.87 (0.08)	89.06 ± 3.59 (0.13)
<i>EEMDv2</i>	97.25 ± 1.50 (0.02)	98.00 ± 0.99 (0.01)	91.94 ± 2.41 (0.06)	94.56 ± 2.39 (0.06)
<i>EEMDv1</i>	87.92 ± 2.90 (0.08)	84.92 ± 2.73 (0.07)	81.78 ± 2.79 (0.08)	75.19 ± 8.74 (0.76)
<i>CEEMDANv1</i>	88.56 ± 2.50 (0.06)	88.89 ± 2.14 (0.05)	85.19 ± 2.60 (0.07)	81.94 ± 9.15 (0.84)
<i>CEEMDANv2</i>	96.08 ± 1.64 (0.03)	97.22 ± 1.74 (0.03)	94.28 ± 2.16 (0.05)	92.31 ± 3.71 (0.14)

En la Tabla 4-14 se muestran los resultados obtenidos a partir del análisis de relevancia SFFS aplicado sobre el conjunto de 13 características seleccionadas previamente (ver Tabla 4-9, umbral $1.5 \geq$), arrojando como características relevantes: {[13], [14], [133], [169], [311], [312]}

Tabla 4-14: Resumen de los resultados promedios obtenidos con los clasificadores a partir del conjunto de 6 características (ver Tabla 4-9, umbral 1.5 \geq)

Técnica de Descomposición	Clasificador -> Promedio \pm Desviación Estándar (Varianza)		
	Normalización señal: bipolar, Normalización de la matriz de características: unipolar		
	HMM	Naive Bayes	KNN
<i>HVD</i>	89.44 \pm 9.01 (0.81)	95.00 \pm 6.42 (0.41)	80.28 \pm 11.88 (1.41)
<i>EMDv3</i>	86.11 \pm 12.25 (1.50)	93.89 \pm 5.76 (0.33)	85.83 \pm 10.75 (1.16)
<i>fastEMD</i>	88.61 \pm 9.15 (0.84)	94.44 \pm 5.05 (0.26)	77.22 \pm 10.01 (1.00)
<i>EEMDv2</i>	91.94 \pm 7.73 (0.60)	97.78 \pm 3.75 (0.14)	84.17 \pm 7.69 (0.59)
<i>EEMDv1</i>	77.22 \pm 15.77 (2.49)	83.06 \pm 12.66 (1.60)	84.72 \pm 11.80 (1.39)
<i>CEEMDANv1</i>	86.39 \pm 11.05 (1.22)	90.28 \pm 6.95 (0.48)	87.78 \pm 9.96 (0.99)
<i>CEEMDANv2</i>	93.33 \pm 10.59 (1.12)	97.22 \pm 5.05 (0.26)	86.11 \pm 8.84 (0.78)
	Normalización señal: unipolar, Normalización de la matriz de características: unipolar		
	HMM	Naive Bayes	KNN
<i>HVD</i>	70.21 \pm 21.33 (4.55)	72.36 \pm 22.87 (5.23)	65.14 \pm 17.39 (3.02)
<i>EMDv3</i>	68.26 \pm 20.05 (4.02)	71.74 \pm 22.33 (4.99)	68.13 \pm 19.41 (3.77)
<i>fastEMD</i>	69.79 \pm 20.78 (4.32)	72.29 \pm 22.74 (5.17)	63.82 \pm 16.01 (2.56)
<i>EEMDv2</i>	71.46 \pm 22.13 (4.90)	73.82 \pm 24.09 (5.80)	67.01 \pm 18.03 (3.25)
<i>EEMDv1</i>	63.19 \pm 16.23 (2.63)	66.60 \pm 18.57 (3.45)	67.15 \pm 18.85 (3.55)
<i>CEEMDANv1</i>	68.33 \pm 19.88 (3.95)	70.00 \pm 20.93 (4.38)	68.68 \pm 19.86 (3.94)
<i>CEEMDANv2</i>	70.97 \pm 22.53 (5.08)	73.75 \pm 24.08 (5.80)	67.85 \pm 19.27 (3.71)

En la Tabla 4-16 se pueden apreciar la precisión obtenida a partir de la validación cruzada con los diferentes clasificadores utilizados a partir del conjunto de 13 características seleccionadas en el análisis de relevancia cuyos índices son: {[13], [14], [133], [169], [177], [179], [180], [297], [299], [305], [309], [311], [312]} (ver Tabla 4-9, umbral de 1.5 \geq). Entre los impactos tendría sobre el sistema de apoyo diagnóstico la mejora de los parámetros de

configuración del clasificador HMM y la optimización en la descomposición de las señales PCG, se encuentran:

- La reducción de los tiempos de entrenamiento de la red y de la validación de los datos.
- El aumento de la precisión del sistema en la clasificación de las señales.
- La reducción del tiempo requerido para la construcción de la matriz de características, debido a la disminución del número de las mismas.

4.2 Esquema de Clasificación de señales PCG basado en HMM

Con respecto al **segundo objetivo específico** se realizaron varias pruebas con el clasificador HMM y el PSOHMM para determinar cuáles deberían ser los parámetros de configuración de la red que permitieran aumentar la precisión del sistema de clasificación, pero debido a la cantidad de parámetros disponibles se seleccionaron el número de estados (S) y el número de gaussianas (M).

La Tabla 4-15 muestra los resultados obtenidos a partir de los clasificadores más relevantes en las pruebas experimentales, donde se puede apreciar que el clasificador Naive Bayes presenta mejores características que el HMM y el PSOHMM. También se debe mencionar, que tanto el HMM como el PSOHMM pueden aumentar su precisión con la apropiada selección de los parámetros de configuración, mejorando la función de optimización del PSO y aumentando los parámetros de selección, lo que implica aumentar el grado de discriminación entre las clases “Normal” y “Soplo”, ya que en las pruebas realizadas para la selección de parámetros de configuración de los clasificadores HMM y PSOHMM solo se tuvieron en cuenta el número de estados (S) y número de gaussianas (M).

Tabla 4-15: Relación comparativa de los clasificadores con resultados más relevantes (Valores dados: Promedio \pm Desviación Estándar (Varianza))

Descomposición CEEMDANv2 con pre-normalización Bipolar y post-normalización Unipolar	Clasificador	Configuración	Parámetros de Selección			Tiempo (seg)		Recursos de Memoria (KB)
			Precisión (%)	Sensibilidad	Especificidad	Entrenamiento	Validación	
	Naive Bayes	---	97.03 \pm 1.53 (0.02)	0.96 \pm 0.02 (0.00)	0.98 \pm 0.02 (0.00)	0.43 \pm 0.01 (0.00)	0.06 \pm 0.01 (0.00)	---
	HMM	Estados: 5	96.69 \pm 1.41 (0.02)	0.95 \pm 0.03 (0.00)	0.98 \pm 0.02 (0.00)	1501.37 \pm 534.85 (286064.45)	3.33 \pm 1.54 (2.37)	1446.76 \pm 614.55 (386730397.64)
	PSOHMM	Gaussianas: 16	92.17 \pm 3.81 (0.14)	0.91 \pm 0.07 (0.00)	0.94 \pm 0.06 (0.00)	12.99 \pm 4.88 (23.86)	1.86 \pm 0.08 (0.01)	1361.40 \pm 687.07 (483395734.91)
	PSOHMM	Estados: 10 Gaussianas: 7	88.81 \pm 6.05 (0.37)	0.86 \pm 0.11 (0.01)	0.92 \pm 0.08 (0.01)	15.67 \pm 5.18 (26.87)	2.38 \pm 0.25 (0.06)	704.50 \pm 265.68 (72278893.71)
	PSOHMM	Estados: 7 Gaussianas: 10	92.00 \pm 3.20 (0.10)	0.89 \pm 0.07 (0.00)	0.95 \pm 0.05 (0.00)	14.70 \pm 4.65 (21.66)	2.05 \pm 0.22 (0.05)	219.20 \pm 269.89 (74591436.80)

Se recomienda utilizar el clasificador PSOHMM y no el Naive Bayes en los casos en los que se requiera aumentar el grado de discriminación del clasificador ya que dicho método se puede optimizar utilizando variantes del PSO incorporando elementos como la mutación de los Algoritmos Genéticos (GA), el ajuste dinámico de la inercia y de los coeficientes de aprendizaje y de aceleración social.

4.3 Esquema de Validación

Con respecto al *tercer objetivo específico*, se utilizó la matriz de confusión para determinar la tasa de aciertos o precisión del clasificador (ver Tabla 4-16). Así mismo para la generación de las curvas ROC y los diagramas de bigotes (ver Anexo B)

Tabla 4-16: Precisión lograda con los clasificadores a partir del conjunto de 13 características (ver Tabla 4-9, umbral de $1.5 \geq$)

<i>Clasificador</i>			
KNN	Naive Bayes	HMM	PSO-HMM
93.94 ± 2.53	97.03 ± 1.53	96.69 ± 1.41	92.17 ± 3.81

4.4 Discusión de los resultados experimentales

Los resultados obtenidos durante el desarrollo de la tesis fueron presentados en un evento de difusión científica internacional, y en un simposio nacional, cada uno con su respectiva publicación.

Poster – Simposio Internacional: Heart murmur detection using ensemble empirical mode decomposition and derivations of the mel-frequency cepstral coefficients on 4-area phonocardiographic signals. Computing in Cardiology 2014; vol. 41, pag. 493-496. ISSN 2325-8861.

Ponencia – Simposio Nacional: Descomposición de señales fonocardiográficas para la detección de soplos cardíacos. Segundo Congreso Multidisciplinar de Perspectivas de la Investigación: La Ingeniería, Fuente de Modernidad y Desarrollo, Institución Universitaria Salazar y Herrera. Noviembre 18 al 20 de 2015 - Medellín, Colombia. ISSN: 2382-3771, vol. 2, pág. 57-61.

Conclusiones y trabajos futuros

5.1 Conclusiones

Se aumentó la velocidad de convergencia del clasificador estocástico HMM, utilizando PSO para seleccionar los valores paramétricos de configuración del modelo, sacrificando un poco el desempeño, el cual se puede aumentar agregando algunas variantes al PSOHMM como la mutación de los GA. También se logra disminuir el costo computacional (recursos de memoria) pero los tiempos de procesamiento aumentan ligeramente en el proceso de descomposición de las señales PCG al utilizar fastEMD en lugar del EMD, debido a que no es necesario desarrollar una serie de interpolaciones (*splines*) cúbicas, sino que se construye una función lineal por tramos, a la cual posteriormente se le aplica una modulación de amplitud (AM) para obtener los IMFs; además de reducir la aparición de mezcla de modos y generar errores comparables e incluso menores que el EMD y el HVD en la reconstrucción de las señales PCG originales. Aunque EMD, EEMD o CEEMDAN se utilizan para descomponer señales de un solo canal, estos tres métodos tienen algunos problemas, tales como la mezcla modo, el tiempo de procesamiento, o el exceso de ruido que se añaden a las señales originales (Huang et al., 2013), lo que hace necesaria la implementación de un filtro de frecuencias como el MFCC y un descriptor estadístico en base a las señales de frecuencia y fase instantáneas obtenidas con el HHT para aumentar la capacidad de discriminación en las componentes, obteniendo mejores resultados al aplicar normalización bipolar a la señal PCG antes de la descomposición (ver Tabla B-1 y B-5).

De acuerdo con el **primer objetivo específico**, se presenta y se valida la metodología para la detección de soplos cardiacos a partir de la representación de señales PCG, mediante constructos de HVD y de CEEMDAN basado en la técnica fastEMD, de los cuales se obtienen características acústicas derivadas de los MFCC, S_MFCC, ST_MFCC, SW_MFCC, STW_MFCC, y características derivadas de los momentos estadísticos en

función de la frecuencia instantánea y la amplitud instantánea, calculados a partir de la HHT y el coeficiente de energía de Shannon. Con estas características se generó un espacio de representación abstracto de alto poder discriminante entre las clases normal y soplo, demostrando un mejor desempeño el S_MFCC respecto a los MFCC convencionales (ver Figura 4-1) calculados directamente de la señal PCG (ver Tabla 4-3 y Tabla 4-4). Adicionalmente, las características basadas en los momentos estadísticos obtenidos de la HHT, incrementan la separabilidad entre señales con soplo y normales. Además, podemos afirmar que en el análisis de relevancia a partir FRS del parámetro de inclusión no afecta la selección de características (ver anexo A).

De acuerdo con el **segundo objetivo específico**, se mejora la velocidad de convergencia al reemplazar el algoritmo EM por el PSO y al optimizar los parámetros de configuración del clasificador estocástico HMM. Sin embargo, se sacrifica un poco la precisión del clasificador. También se puede apreciar que la normalización unipolar de la matriz de características mejora notablemente la precisión de los clasificadores (ver anexo B).

De acuerdo con el **tercer objetivo específico**, para la validación del sistema, se implementó la validación cruzada 70-30 y los resultados obtenidos con el HMM se analizaron y representaron con diferentes técnicas como: Curvas ROC y diagramas de bigotes, teniendo en cuenta los tiempos de procesamiento y costo computacional con una tasa de acierto de aproximadamente el 96% para el HMM con EM, con valores de sensibilidad y especificidad superiores a 0.9, y con cerca del 92% para el PSOHMM, referentes a otros clasificadores como el KNN con un 94.28 % y el Naive Bayes con el 97.22 % de precisión (ver Tabla 4-16).

5.2 Trabajos futuros

Finalmente, como trabajo futuro, se propone mejorar la metodología propuesta en esta tesis mediante un sistema embebido de segmentación automática de señales PCG de los cuatro focos de auscultación cardíaca y un selector de caracterización de estas señales, que permita representar muy cercanamente la dinámica cardíaca mediante un algoritmo de optimización automática que realce las características discriminantes de las señales y atenúe el ruido.

Anexo A: Análisis de Relevancia

En el análisis de relevancia realizado con las matrices de características se utilizaron paralelamente las técnicas PCA, FRS y SFFS, de las cuales se relacionan algunos de los resultados obtenidos organizados como tablas y figuras.

6.1 Análisis de Relevancia con PCA

En el análisis de relevancia con la técnica PCA se obtienen dos componentes con las cuales se puede representar el conjunto de características, sin importar si la normalización de la matriz de características es unipolar o bipolar (ver Tabla A-1). También se puede observar que el índice de las características asociadas gracias a una modificación en el análisis de relevancia PCA, es independiente de la técnica de descomposición.

Tabla A-1: Tabla de resultados de análisis de relevancia con PCA

Técnica de descomposición	Característica	Varianza (%)	
		Componente 1	Componente 2
HVD	[305],[312]	93,62	3,67
EMDv3	[305],[312]	61,35	37,21
fastEMD	[305],[312]	93,87	3,28
EEMDv2	[305],[312]	94,04	3,28
EEMDv1	[305],[312]	71,28	26,79
CEEMDANv1	[305],[312]	76,73	21,11
CEEMDANv2	[305],[312]	93,65	3,68

Figura A-1: Componentes principales de la matriz característica obtenida a partir de la técnica HVD

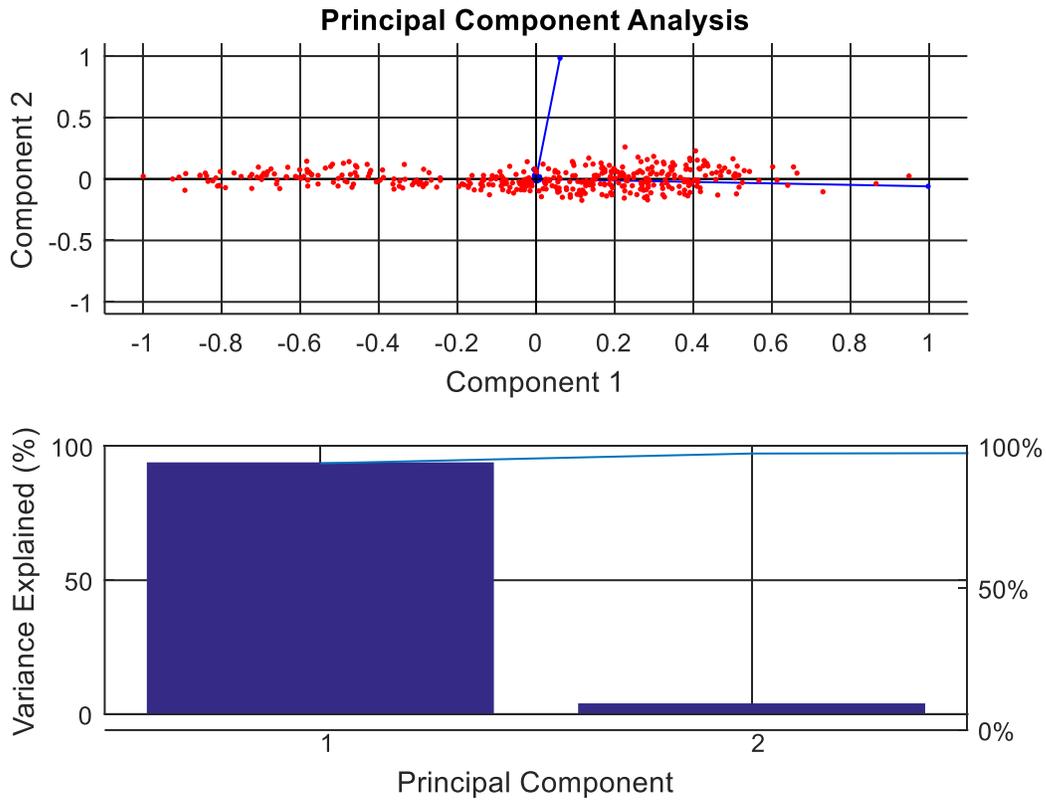
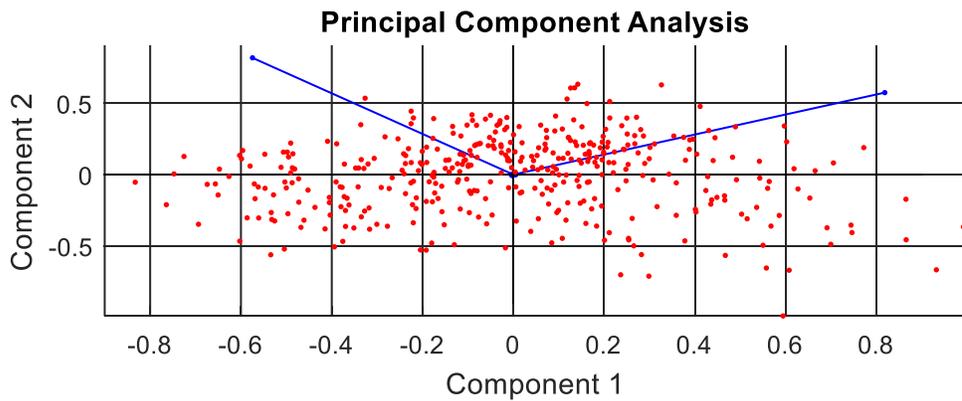


Figura A-2: Componentes principales de la matriz característica obtenida a partir de la técnica EMD



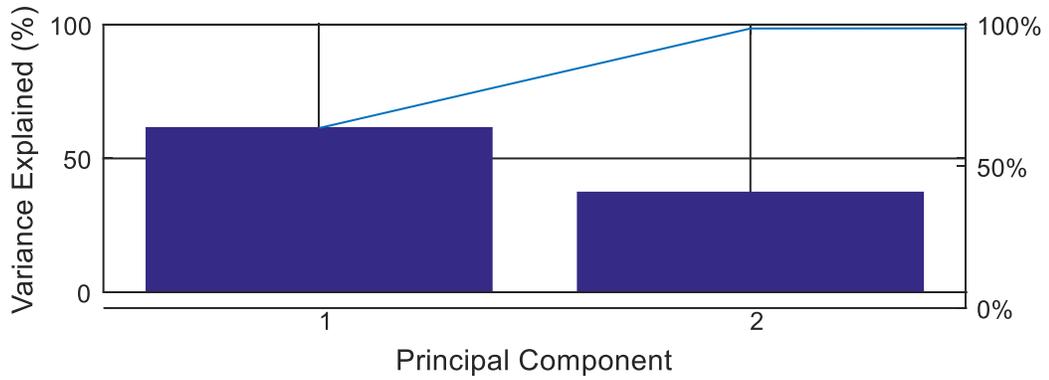


Figura A-3: Componentes principales de la matriz característica obtenida a partir de la técnica fastEMD

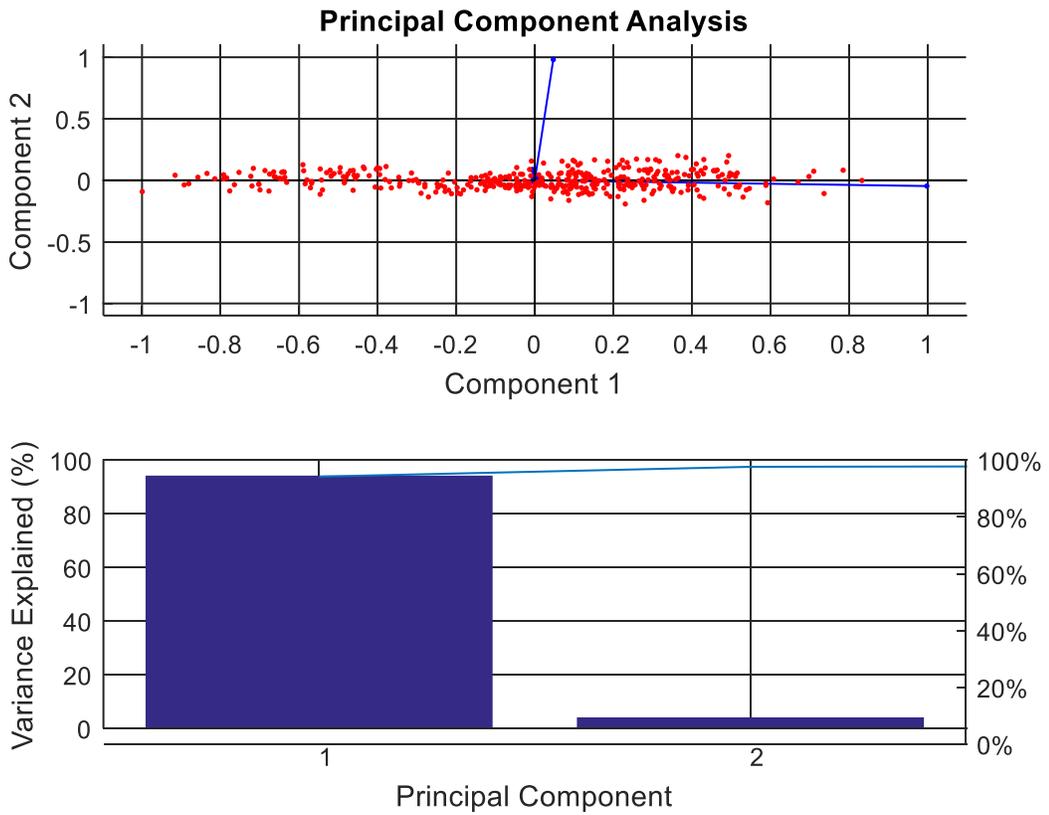


Figura A-4: Componentes principales de la matriz característica obtenida a partir de la técnica EEMDv1

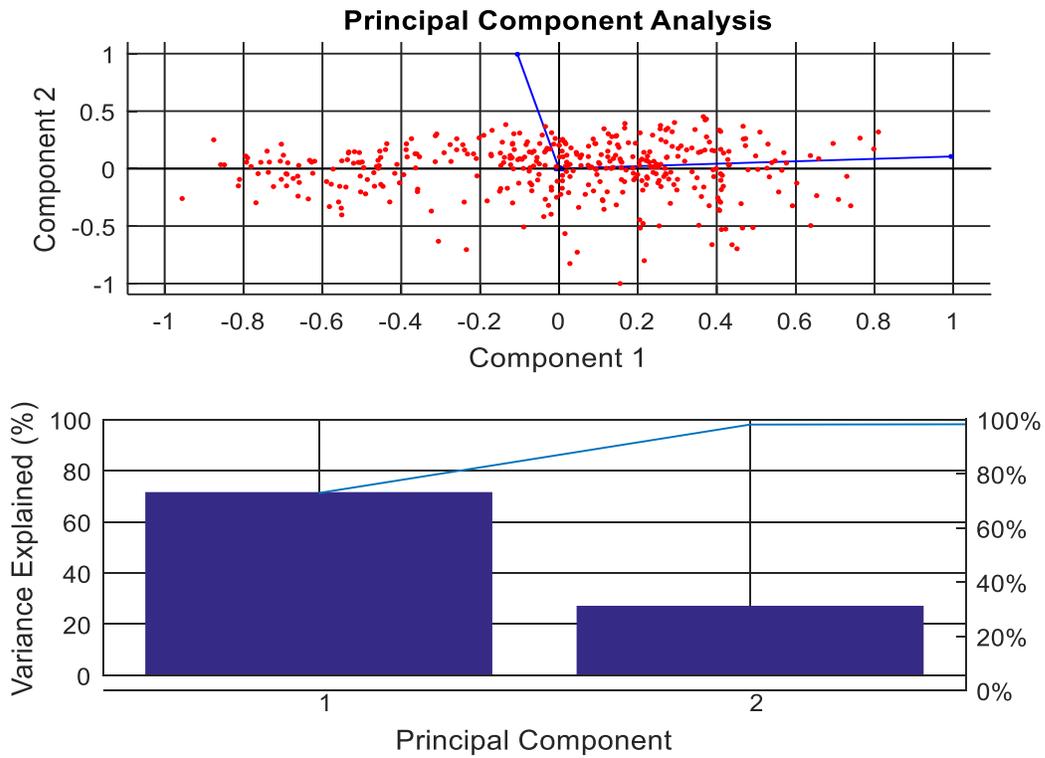
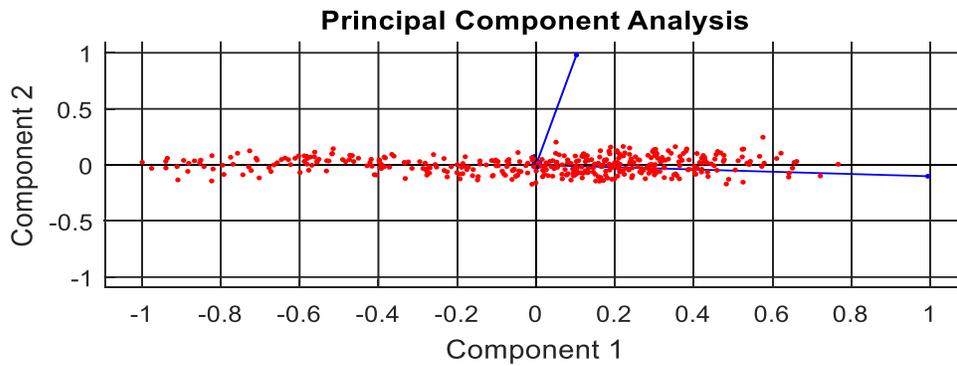


Figura A-5: Componentes principales de la matriz característica obtenida a partir de la técnica EEMDv2



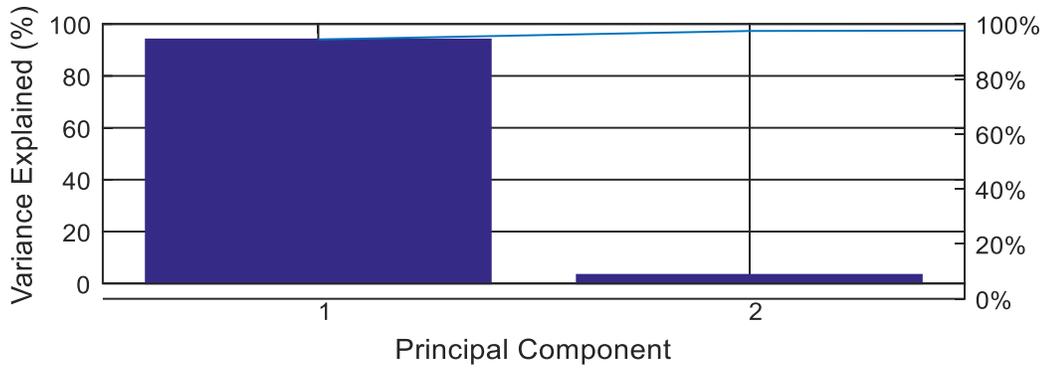


Figura A-6: Componentes principales de la matriz característica obtenida a partir de la técnica CEEMDANv1

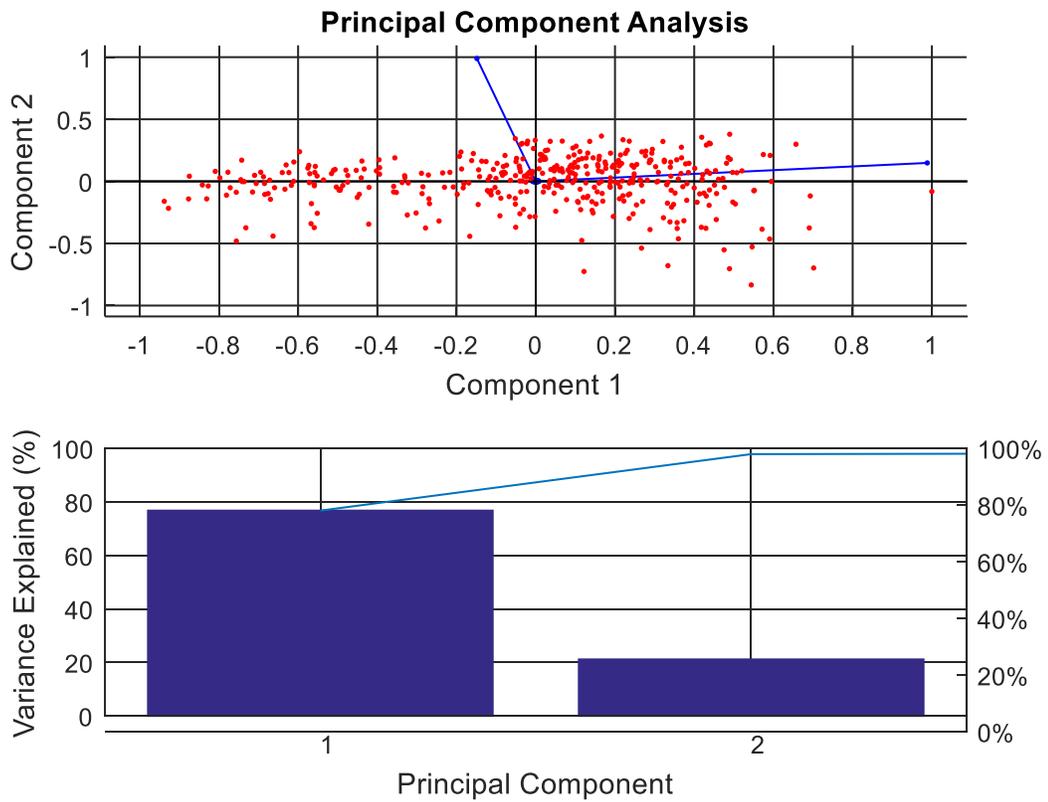
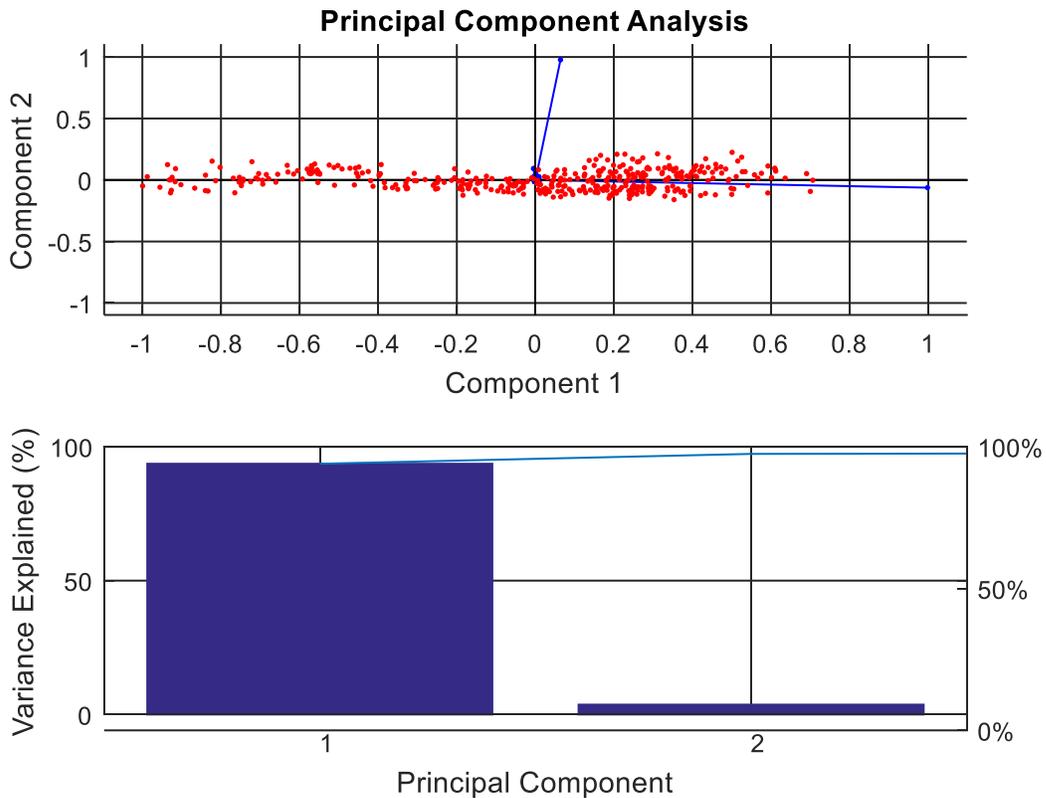


Figura A-7: Componentes principales de la matriz característica obtenida a partir de la técnica CEEMDANv2



6.2 Análisis de Relevancia con FRS

En las Tabla A-2 a la A-4, se muestran los resultados obtenidos del análisis de relevancia con la técnica FRS, a partir de la matriz de características normalizada bipolarmente de las señales PCG descompuesta con EMD, donde se puede observar en la tabla A-3 y A-4 que el parámetro de inclusión no es relevante. Dicha observación también aplica para el análisis de relevancia con FRS en base a las matrices características generadas con las señales Función de Modo Intrínseca (IMFs) obtenidas con las otras técnicas de descomposición utilizadas en este trabajo.

En la Tabla A-2, el número de características seleccionadas aumento con el incremento de la vecindad en la mayoría de los casos, a excepción del análisis con entropía difusa

donde a partir de una vecindad del 0.9 vuelven a disminuir el número de características seleccionadas.

Tabla A-2: FRS con Entropía y Entropía Difusa, sobre matriz característica con normalización bipolar

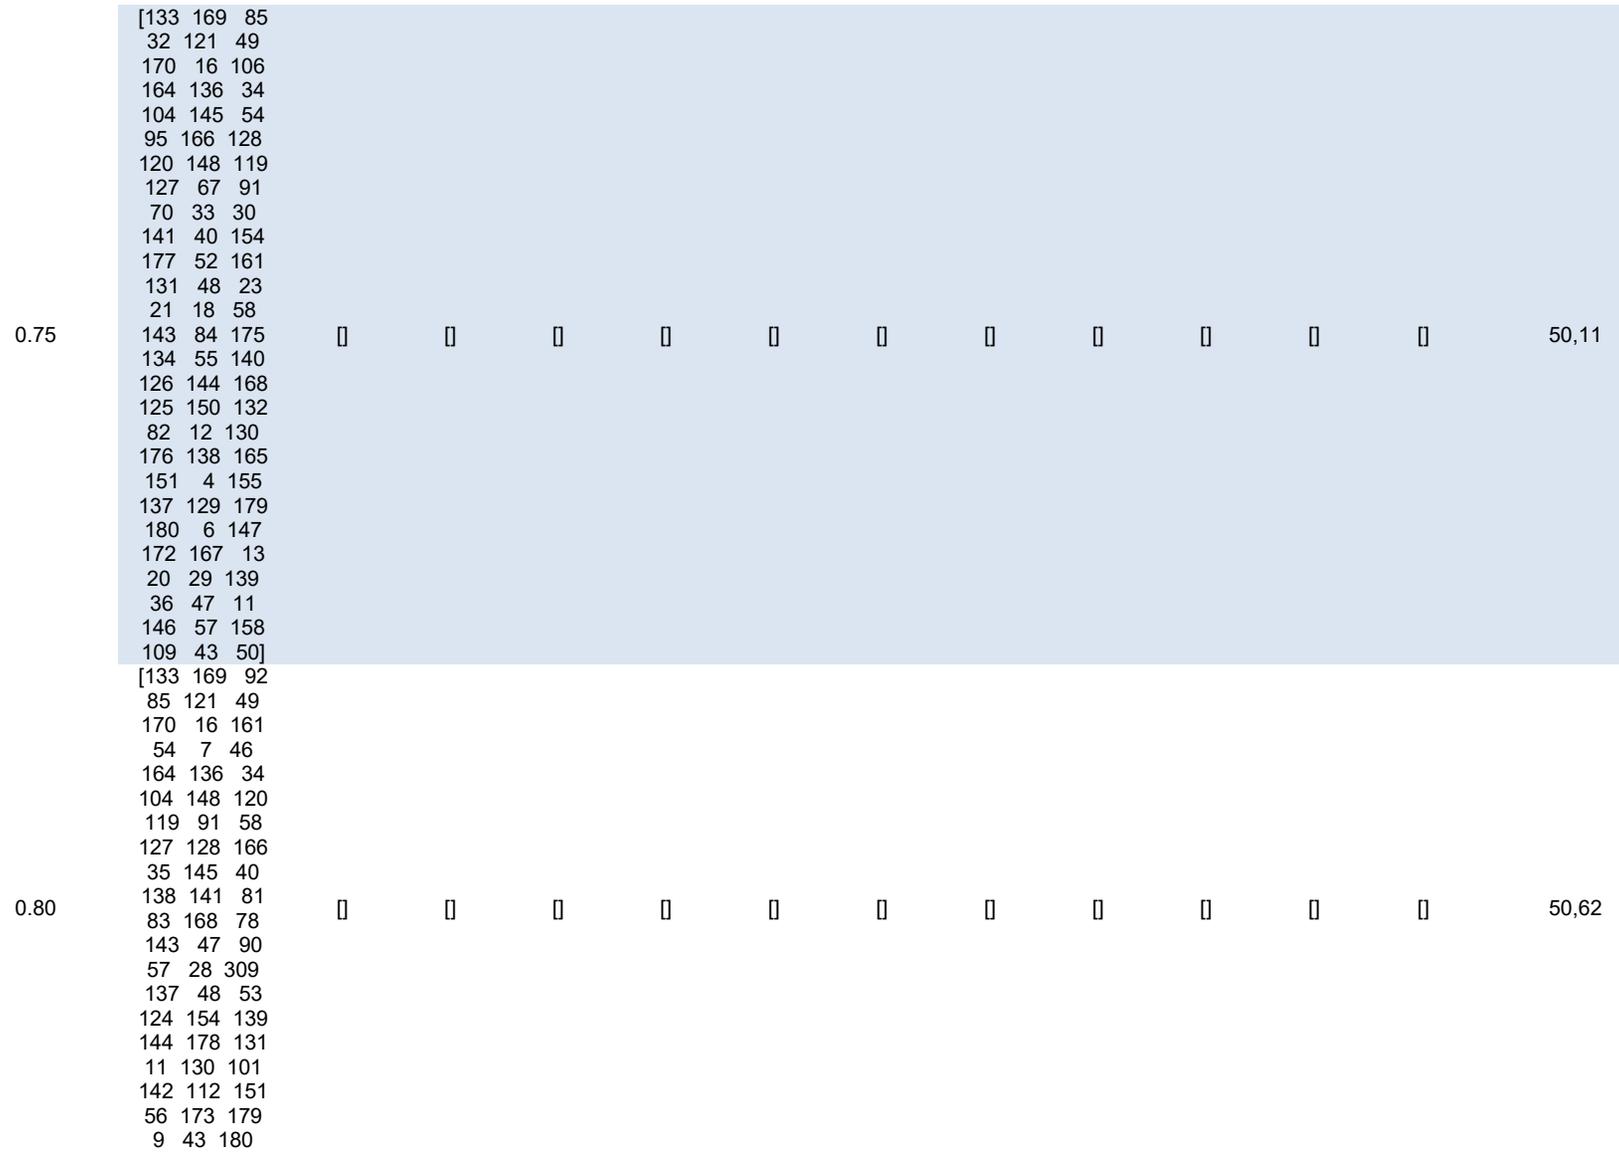
Tamaño Vecindad	Entropía		Entropía difusa	
	Índices de Características	Tiempo de Procesamiento (seg)	Índices de Características	Tiempo de Procesamiento (seg)
0.05	[169 14 46 1]	70,82	[169 14 160 1]	68,65
0.10	[169 14 73 149 6]	65,80	[289 14 205 122 6]	69,46
0.15	[169 14 13 178 20 4]	59,49	[169 14 73 298 200 29]	66,96
0.20	[169 14 13 64 1 179 172 131]	64,14	[289 194 13 178 20 139 214 5]	71,29
0.25	[169 74 73 85 148 92 52 126 9]	66,43	[169 14 13 64 212 95 34 161 47]	73,96
0.30	[169 14 13 85 1 64 120 166 162 125 167 41 9]	74,66	[169 14 13 205 92 137 167 52 174 69 248]	77,33
0.35	[169 74 13 85 121 76 120 92 118 133 54 144 142 175 12]	76,98	[169 14 13 85 32 137 120 34 232 174 150 54 258]	80,49
0.40	[169 110 133 85 121 92 76 82 154 144 155 54 165 131 136 47 10 167]	84,34	[169 14 13 85 121 92 196 133 120 118 155 114 148 33 166 130]	86,39
0.45	[169 133 25 32 110 121 76 30 64 60 166 34 10 54 162 40 33 9 161 59 21]	96,99	[289 14 13 205 110 92 137 253 94 121 240 127 112 167 215 161 119 81 177 166]	99,74
0.50	[169 133 85 32 110 121 76 148 34 166 177 164 178 131 4 141 117 130 60 126 21 138 143 128 44 14 174 35 20 33]	108,68	[289 14 85 13 110 92 196 133 121 268 34 166 60 177 126 54 251 138 47 130 144 284 262 106 161]	107,20
0.55	[169 133 85 92 121 76 110 148 164 90 64 166 170 177 94 140 167 35 118 144 165 126 142 125 100 139 130 55 138 176 151 53 31 20 7 127 60]	119,84	[169 14 85 253 241 92 76 110 148 34 166 177 164 251 264 112 35 239 167 161 176 58 262 54 126 60 113 124 295]	115,61
0.60	[169 133 85 32 110 121 76 49 94 148 154 170 46 30 120 40 144 35 126 7 164 131 177 59 54 180 21 48 141 127 44 12 162 176 53 142 161 130 116 173 37 122 124 175 28 3 45 47]	158,96	[289 14 85 253 241 110 92 196 148 34 166 144 297 35 52 251 120 58 239 167 190 176 126 161 127 142 165 40 175 113 36 164 138 180 124 128 48 159]	132,40
0.65	[169 133 85 92 121 49 170 76 34 50 154 128 120 7 95 40 114 90 164 127 106 177 10 168 131 176 155 165 150 148 142 118 166 12 180 52 9 31 53 175 119 11 141 178 125 57 136 145 18 126 132 33 137 130 56 161 167 48 19 309 47 5 4 28]	176,34	[289 14 110 253 85 241 92 76 49 148 214 170 166 264 60 177 128 131 35 52 246 100 54 119 125 298 296 142 58 72 175 127 161 7 53 164 56 140 137 24 33 36 57 130 143 141 108 167 155 10]	154,82
0.70	[169 133 25 32 121 49 170 76 34 110 120 67 154 46 128 127 35 54 145 30 142 104 165 148 112 55 166 146 12 40 141 162 131 140 13 144 24 143 125 137 21 59 180 161 53 132 167 130 97 126 33 176 175 151 122 178 57 155 56 48 150 174 6 177 58 31 160 20 168 36 11 45 309 138 47 156 9 124 152]	203,62	[169 110 133 205 121 92 196 49 170 148 94 286 46 284 264 35 127 128 100 120 67 90 234 131 177 126 262 52 176 150 58 161 180 113 72 119 295 10 56 151 165 31 130 141 167 107 145 136 122 23 137 117 125 155 18 124 228 138]	168,25
0.75	[133 169 85 32 121 49 170 16 106 164 136 34 104 145 54 95 166 128 120 148 119 127 67 91 70 33 30 141 40 154 177 52 161 131 48 23 21 18 58 143 84 175 134 55 140 126 144 168 125 150 132 82 12 130 176 138 165 151 4 155 137 129 179 180 6 147 172 167 13 20 29 139 36 47 11 146 57 158 109 43 50]	209,44	[169 230 253 85 241 49 212 76 170 88 145 34 154 7 35 120 46 128 127 54 30 164 246 161 177 131 40 144 91 58 232 176 139 119 168 70 33 148 300 150 56 261 132 175 130 53 260 142 155 165 12 166 107 81 138 178 23 174 137 66 97 125 108 24 71 4 151 36 143 179 158 117 152 18 167]	210,90

0.80	[133 169 92 85 121 49 170 16 161 54 7 46 164 136 34 104 148 120 119 91 58 127 128 166 35 145 40 138 141 81 83 168 78 143 47 90 57 28 309 137 48 53 124 154 139 144 178 131 11 130 101 142 112 151 56 173 179 9 43 180 147 140 55 146 176 84 162 152 174 20 45 135 37 149 12 22 6 50]	207,81	[169 133 85 230 241 49 92 76 290 145 28 13 256 104 34 154 106 148 35 166 54 128 240 7 127 30 164 220 239 70 141 91 161 131 177 112 144 33 126 58 259 296 300 48 23 138 72 142 250 155 107 298 175 151 282 125 81 4 137 198 9 167 263 140 285 174 37 71 132 24 179 56 53 146 117 66 55 80 309 152 147 150 124 134 168]	227,50
0.85	[133 169 92 49 170 121 54 85 161 7 16 106 136 120 148 31 145 44 30 55 18 53 166 35 100 168 127 34 81 144 130 177 11 139 151 165 140 107 59 10 52 154 164 33 24 138 58 146 57 28 137 178 176 4 141 174 103 23 12 48 167 150 160 134 125 152 149 143 9 41 45 129 153 20 131 56 155 132 22 135 147]	211,55	[169 253 85 110 121 49 212 76 170 265 13 88 136 224 154 30 115 78 7 94 148 226 120 128 127 164 35 146 166 54 100 141 239 161 31 142 137 131 112 177 201 144 298 258 58 139 48 107 23 151 155 130 176 4 190 125 71 165 260 126 295 167 180 132 12 24 162 9 57 56 113 179 174 33 66 152 168 37 309 143 20 150 147 82 41 134 124 45]	231,90
0.90	[133 169 32 49 170 121 114 7 44 94 76 136 148 164 106 85 161 56 120 58 145 35 55 166 30 53 78 91 146 57 127 21 11 144 130 154 128 138 142 141 112 47 45 48 149 28 178 23 9 143 126 165 10 6 132 180 167 174 125 153 150 152 82 147 40 13 139 119 177 140 131 36 162]	206,97	[169 133 85 230 121 49]	66,28
0.95	[133 49 32 170 54 121 169 104 116 7 16 34 118 136 148 46 164 47 35 113 154 55 144 166 158 40 112 161 145 85 48 11 120 18 30 4 130 13 31 151 139 140 127 81 178 23 149 84 138 152 142 180 141 153 163 157]	159,23	[169 133 85 110 241 49]	67,18
1.00	[]	49,06	[169 133 85 230 49 121]	66,56

En las tablas A-3 y A-4, el parámetro de inclusión no afecta el conjunto de características seleccionadas. En la primera columna de la tabla aparece en tamaño de la vecindad, en la segunda columna el índice de las características arrojadas en el análisis de relevancia con entropía, de la tercera a la antepenúltima columna se relacionan los índices de las características obtenidas con entropía difusa, y en la última columna los tiempos promedios de procesamiento de la información ([], indica que no se obtuvo ninguna característica).

Tabla A-3: FRS con Neighbor, sobre matriz característica con normalización bipolar

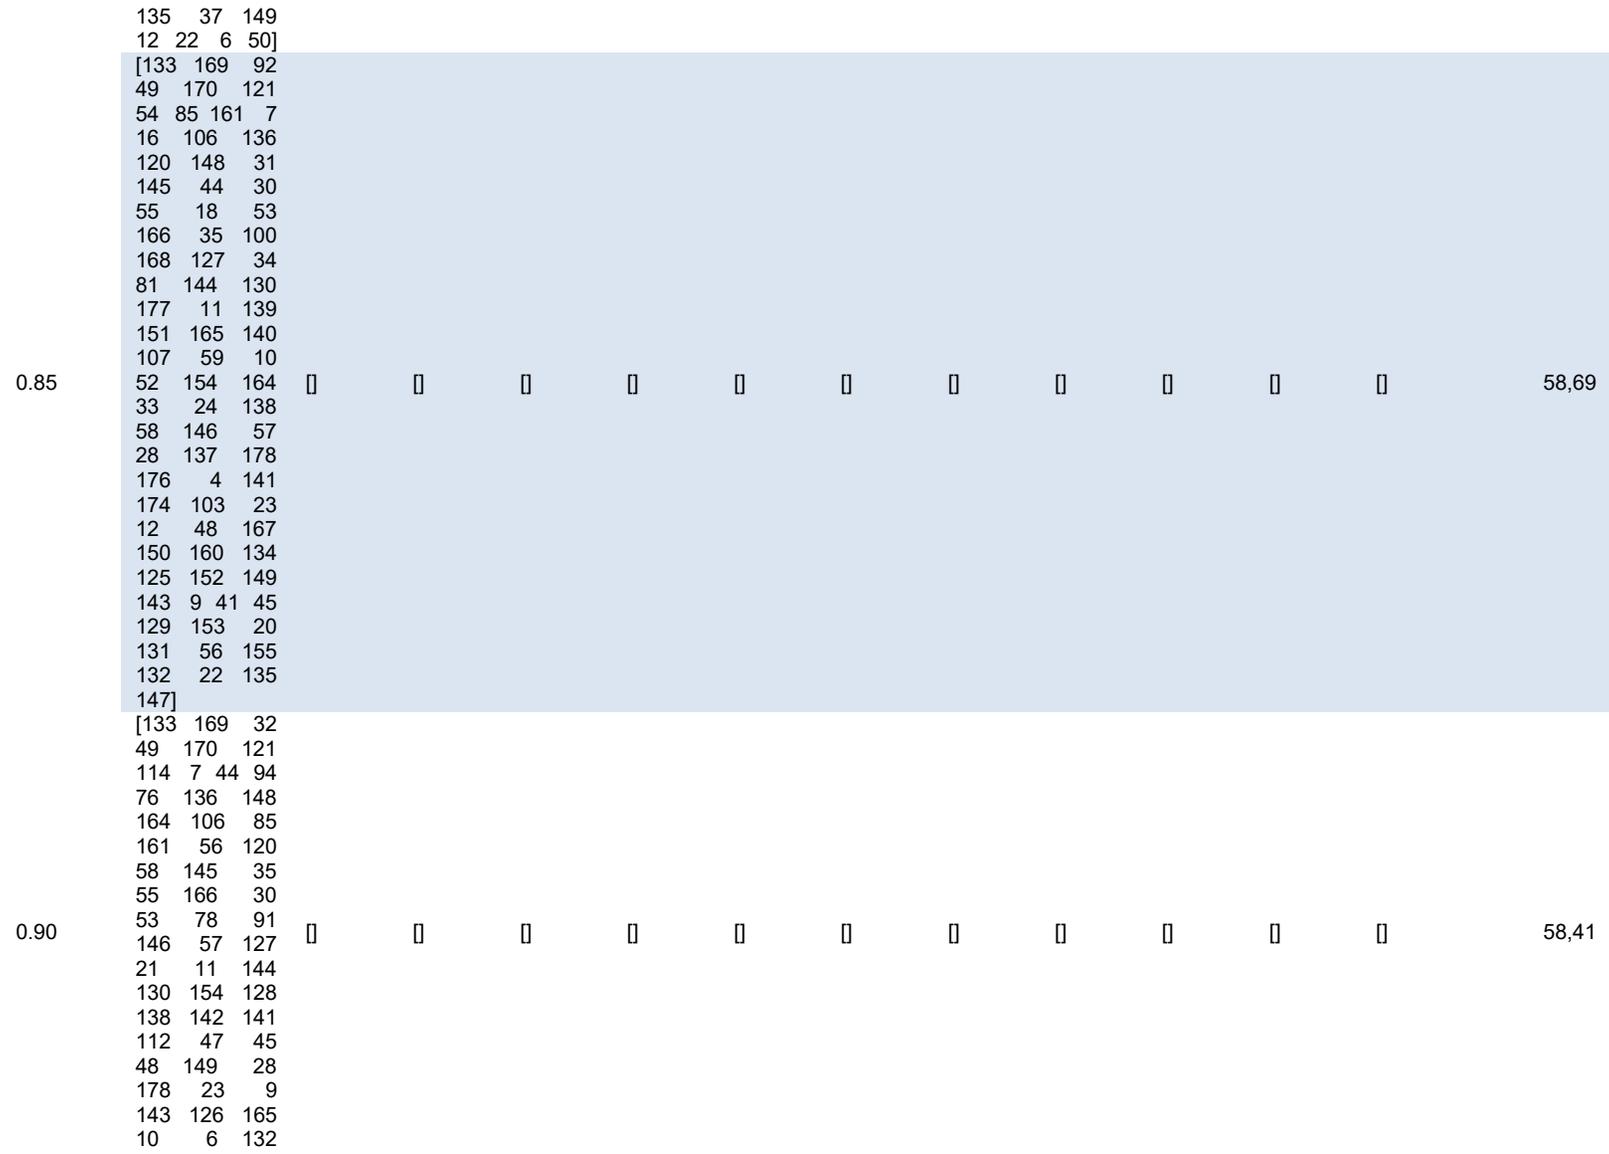
Neighbor



	45 48 149													
	28 178 23													
	9 143 126													
	165 10 6													
	132 180 167													
	174 125 153													
	150 152 82													
	147 40 13													
	139 119 177													
	140 131 36													
	162]													
	[133 49 32													
	170 54 121													
	169 104 116													
	7 16 34													
	118 136 148													
	46 164 47													
	35 113 154													
	55 144 166													
0.95	158 40 112													
	161 145 85	0	0	0	0	0	0	0	0	0	0	0	0	49,34
	48 11 120													
	18 30 4													
	130 13 31													
	151 139 140													
	127 81 178													
	23 149 84													
	138 152 142													
	180 141 153													
1.00	163 157]	0	[1]	[1]	[1]	[1]	[1]	[1]	[1]	[1]	[1]	[1]	[1]	55,86

Tabla A-4: Análisis de relevancia FRS con Neighbor Fuzzy, sobre matriz característica con normalización bipolar

Neighbor Fuzzy



0.05	[169 14 46 58]	58,51	[289 14 46 58]	70,07	[169 14 46 58]	74,25	[169 74 46 134 95 1]	90,95
0.10	[169 14 15 133 143 58 4]	71,97	[169 14 305 20 4 156]	88,70	[169 14 305 32 127 55]	85,46	[169 191 305 243 32 287 150 40 1]	104,54
0.15	[169 14 15 46 1 123 58 149 137 3]	79,07	[169 14 305 306 22 106 32 60 143]	83,76	[169 54 14 305 46 137 1 30 44]	97,23	[169 235 11 98 133 251 161 92 58 232 47 150]	118,65
0.20	[169 14 13 1 124 17 80 46 148 35 38 122 2]	82,01	[169 14 13 61 218 124 131 34 35 154 305]	81,40	[169 311 14 305 9 60 38 58 46 30 3 35]	106,88	[169 311 308 62 98 253 244 303 117 125 161 148 203 52 177 9 166 305 29]	143,80
0.25	[169 74 13 85 75 154 32 115 137 110 30 131 121 164 177 52 159 123]	85,02	[289 14 13 181 124 98 106 60 131 35 125 176 54 148 12 30]	89,77	[308 3 14 169 2 32 148 305 9 131 46 124 121 35 128 52 167 5 10]	143,80	[308 28 289 259 19 84 253 32 114 125 167 242 214 10 297 131 281 162 173 57 112 119 40 106 60 123 56 179 130 58]	199,96
0.30	[169 14 73 110 85 15 32 154 137 148 46 161 124 33 121 133 38 5 177 35 60 30 176 140 12 28 174 162]	104,62	[289 14 13 181 85 75 110 154 32 226 148 124 98 95 125 305 131 177 59 5 167 128 20 57 30]	105,09	[302 3 14 169 2 145 11 124 50 46 32 176 148 167 35 131 177 154 133 60 18 142 149 30 38 128 144 175 17 58]	202,47	[308 162 123 23 194 62 169 265 305 296 10 297 127 32 119 251 149 125 214 262 167 312 140 106 38 53 9 72 120 52 121 95 175 173 57 58 166 126 48 56 5 179 20 132 40 174]	299,07
0.35	[169 74 50 13 32 85 149 15 106 154 148 137 98 20 113 121 133 312 12 35 124 123 93 58 16 128 34 117 170 301 131 167 30 31 165 305 138 1 130 178 52 306 2 152 60 141 144 6 55]	149,52	[289 14 13 110 205 15 212 154 137 148 46 218 127 125 133 243 121 244 215 213 30 296 54 120 12 162 177 53 301 128 144 119 161 237 47]	131,34	[308 28 22 311 2 7 14 169 133 3 19 32 9 29 50 131 145 18 125 134 159 10 35 162 34 38 175 40 167 165 154 55 41 136 176 121 126 60 46 172 301 173 144 312 56 57 11 17 20 128 150]	257,70	[308 28 202 162 311 117 125 84 93 50 48 169 9 2 253 128 23 244 145 298 92 79 94 161 303 242 167 127 78 95 297 58 112 10 120 131 59 154 143 165 121 148 71 126 176 175 38 152 172 306 144 12 156 180 106 47 157]	362,90

170 163 147 171
 123 174 301 129
 302 159 3 55
 30 44 132 164
 150]

0.40	[169 110 133 74 85 92 15 149 311 98 106 121 16 29 34 30 53 137 166 95 44 127 60 165 131 170 80 148 177 178 145 59 47 101 57 33 154 142 123 122 31 125 18 23 301 19 128 4 2 132 58 143 5 175 130 156 312 9 162 24 3 126 56 26 138 10 1 168 158 305 8 306 150 146 27]	198,01	[289 14 85 110 13 15 32 133 121 16 46 218 148 311 137 149 274 35 131 244 34 170 243 245 113 260 78 296 57 80 305 62 55 122 144 40 165 31 142 130 141 59 114 33 175 56 189 159 52 30 150 177 248 23 146 303 127 58]	174,49	[308]	55,83	[308]	63,66
0.45	[169 110 133 14 85 3 92 311 98 149 106 15 302 49 121 34 170 44 154 145 120 28 113 164 117 140 137 312 16 78 90 22 54 124 136 147 131 35 112 33 40 165 144 178 177 69 138 47 31 80 159 161 5 125 10 123 59 23 172 132 12 142 156 176 6 48 26 166 11 168 130 56 19 175 127 39 13 163 180 150 171 141 167 36 4 29]	215,59	[289 14 230 13 85 15 92 253 241 76 311 98 46 149 148 137 308 49 34 154 35 170 312 224 131 166 26 18 53 20 54 63 237 260 62 243 245 122 40 144 31 69 285 132 126 119 33 127 287 41 142 120 23 159 192 145 150 178 128 297 58 301 305 56 244 30 130 70 5 79 176 112 29 175 71 143 36 172 82 180 303 88 157 55]	224,20	[308]	55,27	[308]	62,54
0.50	[169 110 133 14 311 63 308 49 98 32 106 170]	206,57	[289 14 110 13 85 308 49 133 121 75 92 311]	260,59	[308]	57,82	[308]	65,21

	34 121 15 154		98 145 16 106					
	104 145 16 149		104 28 183 136					
	60 53 136 143		154 290 149 35					
	171 25 167 57		34 286 137 312					
	141 142 152 45		26 120 198 30					
	177 312 40 28		82 233 54 20					
	115 165 114 58		40 55 141 12					
	301 164 131 82		117 131 165 140					
	176 21 33 135		262 112 93 134					
	127 134 35 77		297 31 189 125					
	175 132 138 125		70 144 270 124					
	139 11 13 41		23 178 48 41					
	59 168 163 80		132 243 122 296					
	153 31 144 69		247 59 81 168					
	48 47 7 42 26		301 2 305 77					
	150 130 52 174		161 139 250 172					
	180 179 166]		107 138 11 5					
			167 58 162 148					
			293 175 300 159					
			143 147 128 152					
			171 306 56 246					
			158 156 163 29					
			7]					
	[169 50 133 14							
	311 308 109 98							
	63 92 170 46							
	104 121 15 34							
	113 154 55 76							
	13 120 19 161							
	146 301 28 171							
	302 54 145 47		[289 14 230 13					
0.55	111 30 142 112	186,86	308 49 85 133	93,93	[308]	59,27	[308]	67,56
	138 165 11 126		145 311 121 75					
	164 176 136 160		98 212 16]					
	125 130 9 177							
	156 21 166 129							
	141 20 303 43							
	144 40 78 95							
	163 143 7 123							
	149]							
	[169 110 133 98							
	308 49 311 14							
0.60	3 170 13 121 32	137,86	[289 14 110 49	80,69	[308]	60,55	[308]	69,38
	106 55 44 34		308]					
	53 303 154 54							
	15 79 310 60 47							

	161 158 16 141 142 171 117 111]									
	[169 110 133 308 109 38 311 3 170 13 14 46 115 54 303 121 104 53 154 32 7 79 34 117 15 141]	106,92	[289 14 230 49 308]	70,52	[308]	60,54	[308]	68,89		
0.70	[169 133 50 308 109 98 13 311 303 121 170 55 46 3 44 54 154 19 14 113 32 7]	100,50	[289 14 230 49 308]	72,31	[308]	61,70	[]	66,32		
0.75	[169 133 308 110 49 13 38 121 310 303 311 46 115 32 170]	84,54	[289 14 110]	70,36	[]	58,62	[]	67,04		
0.80	[308 169 133 50 302 49 121 303]	73,56	[289 14 230]	78,62	[]	73,44	[]	86,33		
0.85	[308 133 302]	90,45	[289 14 110]	98,23	[]	79,61	[]	91,24		
0.90	[308]	76,96	[289 14 230]	99,89	[]	72,74	[]	82,73		
0.95	[]	76,23	[289 14 230]	81,63	[]	62,56	[]	71,64		
1.00	[]	67,51	[169 14 110]	86,45	[1]	70,94	[]	71,76		

6.3 Análisis de Relevancia con SFFS

En la primera columna de las Tabla A-6 y A-7 aparece el nombre de la técnica de descomposición utilizada, en la segunda columna se pueden apreciar el número de características relevantes seleccionadas del conjunto de caracterización, en la tercera columna podemos apreciar el número de características relevantes al combinar el conjunto de características de la técnica analizada y el HVD. En la cuarta columna se aprecian las características comunes obtenidas en el análisis de la técnica y en la combinación de esta con el HVD. En la quinta y sexta columna se aprecian los tiempos de procesamiento.

Tabla A-6: Relación de características obtenidas con la reducción SFFS con normalización bipolar de la señal

	Características Seleccionadas con SFFS	Tiempo de Procesamiento (seg)
--	--	-------------------------------

<i>Técnica de descomposición</i>	Número Características	Número Características + HVD	Índices de Características Comunes	<i>Técnica de descomposición</i>	+ HVD
HVD	16	16	Todas	0,60	0,0
EMD	27	29	[13],[73]	0,56	1,34
fastEMD	25	25	[60],[303],[306]	0,89	1,21
EEMDv1	24	39	[10],[18],[26],[44],[270],[289],[291]	0,76	2,03
EEMDv2	24	28	[14],[33],[133],[135],[145],[159],[168],[169],[207],[271],[289],[303]	0,41	0,95
CEEMDANv1	32	37	[10],[14],[58],[105],[129],[196],[241],[248],[271]	1,17	1,91
CEEMDANv2	24	26	[25],[29],[154],[171],[253],[289]	0,81	1,40

Tabla A-7: Relación de características obtenidas a partir de la reducción SFFS con normalización unipolar de la señal

<i>Técnica de descomposición</i>	Características Seleccionadas con SFFS			Tiempo de Procesamiento (seg)	
	Número Características	Número Características + HVD	Índices de Características Comunes	<i>Técnica de descomposición</i>	+ HVD
HVD	24	0	[]	0,24	0,00
EMD	26	25	[5],[63],[70],[165],[212],[242]	0,23	0,75
fastEMD	34	32	[16],[49],[60],[171]	0,44	0,96
EEMDv1	25	39	[10],[18],[44],[121],[146],[169],[193],[201],[291]	0,31	1,14
EEMDv2	23	25	[2],[135],[174],[195],[209],[230],[253]	0,32	0,78
CEEMDANv1	27	42	[10],[14],[248],[297]	0,45	1,17
CEEMDANv2	27	25	[29],[121],[289]	0,27	0,63

En la Tabla A-8 podemos apreciar las características arrojadas con el análisis de relevancia a partir de la señal PCG normalizada (bipolar o unipolar), de igual forma normalizando la matriz de características antes de aplicar la técnica SFFS. En la última columna se pueden apreciar los tiempos promedios de procesamiento de los datos.

Tabla A-8: Relación de características obtenidas a partir de la reducción SFFS

Técnicas	Normalización de la señal		Normalización de la matriz de características		Índices de Características	Tiempo de procesamiento (seg)
	Bipolar	Single-pole	Bipolar	Single-pole		
HVD	Si	No	Si	No	[13 14 16 25 38 40 43 50 133 135 141 182 195 207 215 224 229 244 249 274 279 287 295 300 304 311 312]	0,38
	Si	No	No	Si	[13 38 40 43 49 50 133 159 175 180 182 194 195 196 205 207 215 224 244 249 255 261 274 287 304 311 312]	0,24
	No	Si	Si	No	[2 16 25 27 38 43 44 49 50 133 154 175 180 193 194 195 215 220 244 249 255 261 279 287 304 311 312]	0,18
	No	Si	No	Si	[13 14 16 25 27 38 40 43 44 49 50 133 175 180 182 195 215 244 249 255 261 274 279 287 304 311 312]	0,18
EMDv3	Si	No	Si	No	[3 13 14 15 27 47 50 85 86 129 133 149 154 158 159 171 173 182 212 223 242 255 261 289 297 308 311 312]	0,26
	Si	No	No	Si	[3 13 14 15 27 47 50 85 86 103 129 133 149 154 158 159 171 173 182 212 242 255 261 289 297 308 311 312]	0,18
	No	Si	Si	No	[3 13 14 15 27 47 50 62 85 86 129 133 149 154 158 159 171 173 212 223 242 255 261 289 297 308 311 312]	0,19
	No	Si	No	Si	[3 13 14 15 27 47 50 62 86 92 129 133 149 154 158 159 171 173 205 223 242 255 261 289 297 308 311 312]	0,23
fastEMD	Si	No	Si	No	[2 16 40 42 50 130 133 134 136 141 146 162 193 194 205 212 218 223 244 304 311 312]	0,16
	Si	No	No	Si	[2 14 32 38 40 50 124 130 133 134 136 141 146 162 193 196 205 222 223 304 311 312]	0,14
	No	Si	Si	No	[2 14 32 38 40 42 43 50 124 130 133 134 136 141 146 162 193 196 205 304 311 312]	0,14
	No	Si	No	Si	[14 16 25 32 38 40 42 50 124 130 133 136 141 146 162 182 193 223 254 304 311 312]	0,14
EEMDv2	Si	No	Si	No	[2 5 13 25 26 38 39 41 44 133 136 150 151 159 169 171 192 194 195 209 213 223 230 244 245 255 285 294 305 311]	0,21
	Si	No	No	Si	[5 13 15 26 29 33 38 41 44 133 136 150 159 171 182 192 194 205 219 223 230 244 245 255 271 285 289 294 305 311]	0,19
	No	Si	Si	No	[2 5 13 14 33 39 41 43 44 50 133 136 150 151 159 192 195 205 206 209 218 244 245 255 285 289 291 294 305 311]	0,18

EEMDv1	No	Si	No	Si	[2 5 29 33 38 39 41 43 44 136 150 159 171 174 192 193 194 195 205 206 230 244 245 253 255 271 285 289 305 311]	0,19
	Si	No	Si	No	[10 13 15 18 22 26 44 50 74 77 81 85 133 151 169 170 175 180 208 212 246 291 304]	0,14
	Si	No	No	Si	[10 13 15 18 22 26 44 50 74 77 81 85 92 169 170 175 180 208 246 253 271 291 304]	0,15
	No	Si	Si	No	[10 13 15 18 22 26 44 50 77 81 88 92 133 151 175 180 194 205 246 289 290 291 304]	0,14
	No	Si	No	Si	[10 13 15 18 22 26 44 50 74 85 88 92 170 175 180 197 201 246 253 271 289 291 304]	0,14
CEEMDANv1	Si	No	Si	No	[5 10 19 25 38 45 50 51 58 74 76 103 133 144 150 158 169 171 193 199 241 248 265 297 305 306 311]	0,18
	Si	No	No	Si	[5 10 19 25 38 45 50 51 58 73 76 133 144 145 150 169 177 194 199 223 241 248 278 291 305 306 311]	0,18
	No	Si	Si	No	[5 10 19 25 38 45 50 51 58 74 76 103 133 144 150 158 169 193 199 241 248 265 291 297 305 306 311]	0,17
	No	Si	No	Si	[5 10 19 25 38 45 50 51 58 76 79 103 133 144 150 169 193 194 241 248 265 278 291 297 305 306 311]	0,18
CEEMDANv2	Si	No	Si	No	[5 15 27 43 51 133 141 147 150 154 192 193 194 205 212 218 237 242 244 245 295 301 303 305 311]	0,17
	Si	No	No	Si	[5 12 14 25 38 51 57 122 125 133 141 147 150 154 193 195 207 212 223 244 295 301 303 305 311]	0,18
	No	Si	Si	No	[5 12 13 14 25 27 32 38 51 57 122 125 133 154 195 223 244 261 267 270 295 301 303 305 311]	0,17
	No	Si	No	Si	[5 12 13 14 15 25 32 38 43 51 57 122 125 133 141 154 207 244 267 270 295 301 303 305 311]	0,18

Se realiza un análisis combinatorio entre los resultados obtenidos con la normalización bipolar de la matriz de características y la normalización unipolar utilizando el operador x_{nor} para buscar similitudes entre los datos derivados del análisis de relevancia con la técnica SFFS (véase Tabla A-9), de igual forma para la técnica FRS (ver Tabla A-10).

Tabla A-9: Relación de características obtenidas a partir de la reducción SFFS

Técnica de descomposición	Índices de características	Tiempo de procesamiento (seg)
HVD	[14 27 38 43 44 50 133 194 195 207 215 224 244 249 287 304 311 312]	0,24
EMDv3	[3 13 14 15 27 47 50 62 86 129 133 149 154 158 159 171 173 182 242 255 261 289 297 308 311 312]	0,21
fastEMD	[16 40 50 130 133 136 141 146 162 193 196 304 311 312]	0,15
EEMDv2	[5 26 29 41 43 44 136 150 151 159 192 206 209 223 244 245 255 271 285 305 311]	0,19
EEMDv1	[10 13 15 18 22 26 44 50 88 133 151 169 175 180 208 246 253 271 289 291 304]	0,14
CEEMDANv1	[5 10 19 25 38 45 50 51 58 74 76 133 144 150 158 169 194 241 248 278 305 306 311]	0,18
CEEMDANv2	[5 13 15 27 32 43 51 133 147 150 154 193 195 207 212 223 244 267 270 295 301 303 305 311]	0,18

Tabla A-10: Relación de características obtenidas a partir de la reducción FRS

Técnica de descomposición	Número Características	Índices de Características	Tiempo de Procesamiento (seg)
HVD	13	[6 12 14 18 54 58 121 122 133 164 169 175 311]	545,69
EMDv3	6	[126 131 133 161 169 308]	421,90
fastEMD	18	[4 9 13 28 32 50 60 127 132 133 142 143 151 163 165 179 311 312]	561,06
EEMDv2	15	[13 14 16 25 49 53 59 124 128 149 152 166 177 305 311]	610,28
EEMDv1	5	[15 148 161 308 311]	476,31
CEEMDANv1	6	[50 128 132 148 164 165]	522,23
CEEMDANv2	12	[10 11 14 24 60 125 152 163 175 305 311 312]	498,21

Anexo B: Clasificadores y Esquemas de validación

En las Tabla B-1 a B-5 se pueden apreciar los valores promedio (en porcentaje) obtenidos a partir de la validación cruzada del entrenamiento con el clasificador HMM (Estados: 5, Gaussianas: 16) utilizando las características obtenidas a partir de cada análisis de relevancia de manera independiente (ver Tabla A-6 a Tabla **A-10**). Teniendo en cuenta la normalización de los datos antes de la descomposición de las señales y la normalización de los datos antes de aplicar análisis de relevancia, tanto bipolar como unipolar. Se puede observar que se obtiene una mayor tasa de acierto al utilizar la normalización unipolar de la señal y de la matriz de características.

Tabla B-1: Relación comparativa en base a la precisión obtenida en la validación de los clasificadores utilizados (normalización señal: bipolar, normalización matriz característica: bipolar).

<i>Técnica Descomposición</i>	Análisis de Relevancia			Clasificador -> Promedio ± Desviación Estándar (Varianza)			
	PCA	FRS	SFFS	HMM	Naive Bayes	KNN	PSOHMM
HVD	Si	No	No	73.72 ± 2.90 (0.08)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
HVD	No	Si	No	81.50 ± 3.76 (0.14)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
HVD	No	No	Si	74.19 ± 3.01 (0.09)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
EMDv3	Si	No	No	51.53 ± 3.58 (0.13)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
EMDv3	No	Si	No	64.81 ± 2.69 (0.07)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
EMDv3	No	No	Si	52.58 ± 3.37 (0.11)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
fastEMD	Si	No	No	52.83 ± 3.94 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
fastEMD	No	Si	No	72.89 ± 4.26 (0.18)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)

fastEMD	No	No	Si	51.94 ± 3.76 (0.14)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
EEMDv2	Si	No	No	51.22 ± 2.91 (0.08)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
EEMDv2	No	Si	No	84.28 ± 3.51 (0.12)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
EEMDv2	No	No	Si	51.31 ± 3.56 (0.13)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
EEMDv1	Si	No	No	48.03 ± 2.95 (0.09)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
EEMDv1	No	Si	No	70.47 ± 3.69 (0.14)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
EEMDv1	No	No	Si	49.03 ± 4.40 (0.19)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
CEEMDANv1	Si	No	No	53.25 ± 4.13 (0.17)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
CEEMDANv1	No	Si	No	71.97 ± 3.20 (0.10)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
CEEMDANv1	No	No	Si	53.31 ± 4.00 (0.16)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
CEEMDANv2	Si	No	No	59.53 ± 2.62 (0.07)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
CEEMDANv2	No	Si	No	67.97 ± 4.74 (0.22)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)
CEEMDANv2	No	No	Si	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)	59.81 ± 3.89 (0.15)

Tabla B-2: Relación comparativa en base a la precisión obtenida en la validación de los clasificadores utilizados (normalización señal: bipolar, normalización matriz característica: unipolar).

Técnica de Descomposición	Análisis de Relevancia			Clasificador -> Promedio ± Desviación Estándar (Varianza)			
	PCA	FRS	SFFS	HMM	Naive Bayes	KNN	PSOHHM
HVD	Si	No	No	75.78 ± 3.32 (0.11)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
HVD	No	Si	No	94.86 ± 1.81 (0.03)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
HVD	No	No	Si	96.69 ± 1.72 (0.03)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
EMDv3	Si	No	No	76.08 ± 3.38 (0.11)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
EMDv3	No	Si	No	86.89 ± 2.43 (0.06)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
EMDv3	No	No	Si	95.81 ± 1.94 (0.04)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
fastEMD	Si	No	No	82.03 ± 3.05 (0.09)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
fastEMD	No	Si	No	95.03 ± 1.57 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)

fastEMD	No	No	Si	97.22 ± 1.46 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
EEMDv2	Si	No	No	54.75 ± 3.94 (0.16)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
EEMDv2	No	Si	No	96.92 ± 1.60 (0.03)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
EEMDv2	No	No	Si	97.08 ± 1.41 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
EEMDv1	Si	No	No	67.58 ± 3.03 (0.09)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
EEMDv1	No	Si	No	72.14 ± 4.06 (0.17)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
EEMDv1	No	No	Si	93.61 ± 2.33 (0.05)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
CEEMDANv1	Si	No	No	73.33 ± 2.74 (0.08)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
CEEMDANv1	No	Si	No	55.22 ± 3.60 (0.13)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
CEEMDANv1	No	No	Si	93.86 ± 2.22 (0.05)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
CEEMDANv2	Si	No	No	53.64 ± 3.64 (0.13)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
CEEMDANv2	No	Si	No	97.78 ± 1.16 (0.01)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)
CEEMDANv2	No	No	Si	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)	97.00 ± 1.38 (0.02)

Tabla B-3: Relación comparativa en base a la precisión obtenida en la validación de los clasificadores utilizados (normalización señal: unipolar, normalización matriz característica: bipolar).

<i>Técnica</i> <i>Descomposición</i>	Análisis de Relevancia			Clasificador -> Promedio ± Desviación Estándar (Varianza)			
	PCA	FRS	SFFS	HMM	Naive Bayes	KNN	PSOHMM
HVD	Si	No	No	74.19 ± 3.01 (0.09)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
HVD	No	Si	No	84.14 ± 3.26 (0.11)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
HVD	No	No	Si	74.00 ± 5.23 (0.27)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
EMDv3	Si	No	No	52.58 ± 3.37 (0.11)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
EMDv3	No	Si	No	64.92 ± 3.41 (0.12)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
EMDv3	No	No	Si	52.92 ± 4.00 (0.16)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
fastEMD	Si	No	No	52.86 ± 4.20 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
fastEMD	No	Si	No	79.94 ± 3.87 (0.15)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
fastEMD	No	No	Si	53.44 ± 4.11 (0.17)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)

EEMDv2	Si	No	No	51.56 ± 4.32 (0.19)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
EEMDv2	No	Si	No	85.58 ± 3.66 (0.13)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
EEMDv2	No	No	Si	52.33 ± 4.61 (0.21)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
EEMDv1	Si	No	No	49.42 ± 4.61 (0.21)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
EEMDv1	No	Si	No	81.86 ± 3.50 (0.12)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
EEMDv1	No	No	Si	48.50 ± 3.71 (0.14)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
CEEMDANv1	Si	No	No	53.31 ± 3.67 (0.13)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
CEEMDANv1	No	Si	No	73.67 ± 4.14 (0.17)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
CEEMDANv1	No	No	Si	53.31 ± 3.67 (0.13)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
CEEMDANv2	Si	No	No	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
CEEMDANv2	No	Si	No	64.97 ± 3.71 (0.14)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)
CEEMDANv2	No	No	Si	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)	58.58 ± 4.26 (0.18)

Tabla B-4: Relación comparativa en base a la precisión obtenida en la validación de los clasificadores utilizados (normalización señal: unipolar, normalización matriz característica: unipolar).

Técnica Descomposición	Análisis de Relevancia			Clasificador -> Promedio ± Desviación Estándar (Varianza)			
	PCA	FRS	SFFS	HMM	Naive Bayes	KNN	PSOHMM
HVD	Si	No	No	76.19 ± 2.98 (0.09)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
HVD	No	Si	No	95.33 ± 1.60 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
HVD	No	No	Si	96.36 ± 1.19 (0.01)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
EMDv3	Si	No	No	76.17 ± 2.56 (0.07)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
EMDv3	No	Si	No	86.22 ± 2.39 (0.06)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
EMDv3	No	No	Si	95.31 ± 1.91 (0.04)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
fastEMD	Si	No	No	81.58 ± 3.38 (0.11)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
fastEMD	No	Si	No	95.08 ± 1.42 (0.02)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
fastEMD	No	No	Si	96.08 ± 1.87 (0.04)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)

EEMDv2	Si	No	No	54.61 ± 3.12 (0.10)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
EEMDv2	No	Si	No	94.06 ± 12.04 (1.45)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
EEMDv2	No	No	Si	97.44 ± 1.42 (0.02)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
EEMDv1	Si	No	No	68.64 ± 2.86 (0.08)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
EEMDv1	No	Si	No	71.81 ± 5.10 (0.26)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
EEMDv1	No	No	Si	93.86 ± 1.69 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
CEEMDANv1	Si	No	No	73.44 ± 3.59 (0.13)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
CEEMDANv1	No	Si	No	54.92 ± 3.53 (0.12)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
CEEMDANv1	No	No	Si	93.78 ± 2.33 (0.05)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
CEEMDANv2	Si	No	No	53.22 ± 3.15 (0.10)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
CEEMDANv2	No	Si	No	97.56 ± 1.09 (0.01)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)
CEEMDANv2	No	No	Si	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)	97.06 ± 1.80 (0.03)

Se demuestra con base en los resultados experimentales que los clasificadores objetos de estudio, tienen mejor respuesta en los casos donde se realiza una normalización unipolar de la matriz de características (ver Tabla B-5).

Tabla B-5: Validación de resultados para el clasificador HMM en las diferentes combinaciones utilizadas de normalización de la señal y la matriz de características.

Técnica de Descomposición	Análisis de Relevancia			Clasificador HMM -> Promedio ± Desviación Estándar (Varianza)			
	PCA	FRS	SFFS	Bipolar - Bipolar	Bipolar - Unipolar	Unipolar - Bipolar	Unipolar - Unipolar
HVD	Si	No	No	73.72 ± 2.90 (0.08)	75.78 ± 3.32 (0.11)	74.19 ± 3.01 (0.09)	76.19 ± 2.98 (0.09)
HVD	No	Si	No	81.50 ± 3.76 (0.14)	94.86 ± 1.81 (0.03)	84.14 ± 3.26 (0.11)	95.33 ± 1.60 (0.03)
HVD	No	No	Si	74.19 ± 3.01 (0.09)	96.69 ± 1.72 (0.03)	74.00 ± 5.23 (0.27)	96.36 ± 1.19 (0.01)
EMD	Si	No	No	51.53 ± 3.58 (0.13)	76.08 ± 3.38 (0.11)	52.58 ± 3.37 (0.11)	76.17 ± 2.56 (0.07)
EMD	No	Si	No	64.81 ± 2.69 (0.07)	86.89 ± 2.43 (0.06)	64.92 ± 3.41 (0.12)	86.22 ± 2.39 (0.06)
EMD	No	No	Si	52.58 ± 3.37 (0.11)	95.81 ± 1.94 (0.04)	52.92 ± 4.00 (0.16)	95.31 ± 1.91 (0.04)

fastEMD	Si	No	No	52.83 ± 3.94 (0.15)	82.03 ± 3.05 (0.09)	52.86 ± 4.20 (0.18)	81.58 ± 3.38 (0.11)
fastEMD	No	Si	No	72.89 ± 4.26 (0.18)	95.03 ± 1.57 (0.02)	79.94 ± 3.87 (0.15)	95.08 ± 1.42 (0.02)
fastEMD	No	No	Si	51.94 ± 3.76 (0.14)	97.22 ± 1.46 (0.02)	53.44 ± 4.11 (0.17)	96.08 ± 1.87 (0.04)
EEMDv2	Si	No	No	51.22 ± 2.91 (0.08)	54.75 ± 3.94 (0.16)	51.56 ± 4.32 (0.19)	54.61 ± 3.12 (0.10)
EEMDv2	No	Si	No	84.28 ± 3.51 (0.12)	96.92 ± 1.60 (0.03)	85.58 ± 3.66 (0.13)	94.06 ± 12.04 (1.45)
EEMDv2	No	No	Si	51.31 ± 3.56 (0.13)	97.08 ± 1.41 (0.02)	52.33 ± 4.61 (0.21)	97.44 ± 1.42 (0.02)
EEMDv1	Si	No	No	48.03 ± 2.95 (0.09)	67.58 ± 3.03 (0.09)	49.42 ± 4.61 (0.21)	68.64 ± 2.86 (0.08)
EEMDv1	No	Si	No	70.47 ± 3.69 (0.14)	72.14 ± 4.06 (0.17)	81.86 ± 3.50 (0.12)	71.81 ± 5.10 (0.26)
EEMDv1	No	No	Si	49.03 ± 4.40 (0.19)	93.61 ± 2.33 (0.05)	48.50 ± 3.71 (0.14)	93.86 ± 1.69 (0.03)
CEEMDANv1	Si	No	No	53.25 ± 4.13 (0.17)	73.33 ± 2.74 (0.08)	53.31 ± 3.67 (0.13)	73.44 ± 3.59 (0.13)
CEEMDANv1	No	Si	No	71.97 ± 3.20 (0.10)	55.22 ± 3.60 (0.13)	73.67 ± 4.14 (0.17)	54.92 ± 3.53 (0.12)
CEEMDANv1	No	No	Si	53.31 ± 4.00 (0.16)	93.86 ± 2.22 (0.05)	53.31 ± 3.67 (0.13)	93.78 ± 2.33 (0.05)
CEEMDANv2	Si	No	No	59.53 ± 2.62 (0.07)	53.64 ± 3.64 (0.13)	58.58 ± 4.26 (0.18)	53.22 ± 3.15 (0.10)
CEEMDANv2	No	Si	No	67.97 ± 4.74 (0.22)	97.78 ± 1.16 (0.01)	64.97 ± 3.71 (0.14)	97.56 ± 1.09 (0.01)
CEEMDANv2	No	No	Si	59.81 ± 3.89 (0.15)	97.00 ± 1.38 (0.02)	58.58 ± 4.26 (0.18)	97.06 ± 1.80 (0.03)

En las Tabla B-6 a la Tabla B-9 se pueden observar además de los valores de precisión del clasificador, la sensibilidad y la especificidad, obtenidos con los valores promedios de los resultados de la validación cruzada 70-30 con 30 “*folds*”, se puede identificar el clasificador HMM (ver Tabla B-6) como el mejor resultado 97.00 ± 1.38 (0.02) % el cual se encuentra asociado a la técnica de descomposición CEEMANv2 como una variante de la fastEMD la cual se entrenó con una matriz de características reducida con FRS.

La modificación generada al introducir PSO en el entrenamiento de la red HMM en lugar del algoritmo expectativa de maximización (EM) radica en la forma como se determina el máximo con el cual se realizará la siguiente iteración en el entrenamiento.

Tabla B-6: Precisión, sensibilidad y especificidad clasificador HMM (Estados: 5, Gaussianas: 16).

Técnica de Descomposición	Clasificador -> Promedio ± Desviación Estándar (Varianza)								
	Análisis de Relevancia			Normalización Señal: Bipolar, Normalización Matriz Característica: Unipolar			Normalización Señal: Unipolar, Normalización Matriz Característica: Unipolar		
	PCA	FRS	SFFS	Precisión (%)	Sensibilidad	Especificidad	Precisión (%)	Sensibilidad	Especificidad
HVD	Si	No	No	75.78 ± 3.32 (0.11)	0.69 ± 0.05 (0.00)	0.83 ± 0.03 (0.00)	74.97 ± 3.19 (0.10)	0.70 ± 0.05 (0.00)	0.80 ± 0.05 (0.00)
HVD	No	Si	No	94.86 ± 1.81 (0.03)	0.95 ± 0.04 (0.00)	0.95 ± 0.02 (0.00)	88.96 ± 6.81 (0.46)	0.90 ± 0.07 (0.00)	0.88 ± 0.09 (0.01)
HVD	No	No	Si	96.69 ± 1.72 (0.03)	0.96 ± 0.03 (0.00)	0.98 ± 0.02 (0.00)	85.31 ± 11.70 (1.37)	0.82 ± 0.15 (0.02)	0.89 ± 0.10 (0.01)
EMDv3	Si	No	No	76.08 ± 3.38 (0.11)	0.66 ± 0.06 (0.00)	0.86 ± 0.05 (0.00)	64.09 ± 12.51 (1.56)	0.54 ± 0.13 (0.02)	0.74 ± 0.14 (0.02)
EMDv3	No	Si	No	86.89 ± 2.43 (0.06)	0.82 ± 0.04 (0.00)	0.92 ± 0.03 (0.00)	75.71 ± 11.23 (1.26)	0.75 ± 0.09 (0.01)	0.77 ± 0.15 (0.02)
EMDv3	No	No	Si	95.81 ± 1.94 (0.04)	0.95 ± 0.03 (0.00)	0.96 ± 0.03 (0.00)	74.15 ± 21.69 (4.70)	0.69 ± 0.26 (0.07)	0.79 ± 0.18 (0.03)
fastEMD	Si	No	No	82.03 ± 3.05 (0.09)	0.73 ± 0.05 (0.00)	0.91 ± 0.03 (0.00)	67.33 ± 14.99 (2.25)	0.63 ± 0.12 (0.01)	0.71 ± 0.20 (0.04)
fastEMD	No	Si	No	95.03 ± 1.57 (0.02)	0.95 ± 0.03 (0.00)	0.95 ± 0.03 (0.00)	85.74 ± 10.15 (1.03)	0.87 ± 0.10 (0.01)	0.85 ± 0.12 (0.01)
fastEMD	No	No	Si	97.22 ± 1.46 (0.02)	0.98 ± 0.02 (0.00)	0.97 ± 0.02 (0.00)	74.67 ± 22.28 (4.97)	0.74 ± 0.24 (0.06)	0.75 ± 0.23 (0.05)
EEMDv2	Si	No	No	54.75 ± 3.94 (0.16)	0.67 ± 0.09 (0.01)	0.42 ± 0.09 (0.01)	53.03 ± 3.94 (0.16)	0.67 ± 0.09 (0.01)	0.40 ± 0.09 (0.01)
EEMDv2	No	Si	No	96.92 ± 1.60 (0.03)	0.95 ± 0.03 (0.00)	0.99 ± 0.01 (0.00)	90.21 ± 8.46 (0.72)	0.90 ± 0.13 (0.02)	0.91 ± 0.10 (0.01)
EEMDv2	No	No	Si	97.08 ± 1.41 (0.02)	0.96 ± 0.03 (0.00)	0.98 ± 0.02 (0.00)	74.54 ± 23.02 (5.30)	0.80 ± 0.18 (0.03)	0.69 ± 0.29 (0.09)
EEMDv1	Si	No	No	67.58 ± 3.03 (0.09)	0.64 ± 0.05 (0.00)	0.71 ± 0.05 (0.00)	58.42 ± 10.33 (1.07)	0.56 ± 0.10 (0.01)	0.60 ± 0.13 (0.02)
EEMDv1	No	Si	No	72.14 ± 4.06 (0.17)	0.61 ± 0.05 (0.00)	0.83 ± 0.05 (0.00)	74.07 ± 6.12 (0.37)	0.66 ± 0.11 (0.01)	0.83 ± 0.06 (0.00)

EEMDv1	No	No	Si	93.61 ± 2.33 (0.05)	0.92 ± 0.04 (0.00)	0.95 ± 0.03 (0.00)	71.25 ± 22.80 (5.20)	0.72 ± 0.22 (0.05)	0.71 ± 0.25 (0.06)
CEEMDANv1	Si	No	No	73.33 ± 2.74 (0.08)	0.74 ± 0.05 (0.00)	0.73 ± 0.04 (0.00)	63.33 ± 10.69 (1.14)	0.64 ± 0.11 (0.01)	0.63 ± 0.13 (0.02)
CEEMDANv1	No	Si	No	55.22 ± 3.60 (0.13)	0.67 ± 0.06 (0.00)	0.43 ± 0.08 (0.01)	63.94 ± 9.63 (0.93)	0.71 ± 0.08 (0.01)	0.57 ± 0.16 (0.02)
CEEMDANv1	No	No	Si	93.86 ± 2.22 (0.05)	0.93 ± 0.03 (0.00)	0.94 ± 0.04 (0.00)	73.56 ± 20.58 (4.23)	0.73 ± 0.21 (0.05)	0.74 ± 0.22 (0.05)
CEEMDANv2	Si	No	No	53.64 ± 3.64 (0.13)	0.49 ± 0.15 (0.02)	0.58 ± 0.14 (0.02)	56.24 ± 4.45 (0.20)	0.57 ± 0.12 (0.02)	0.56 ± 0.10 (0.01)
CEEMDANv2	No	Si	No	97.78 ± 1.16 (0.01)	0.96 ± 0.02 (0.00)	0.99 ± 0.01 (0.00)	82.07 ± 16.00 (2.56)	0.82 ± 0.15 (0.02)	0.83 ± 0.18 (0.03)
CEEMDANv2	No	No	Si	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)

Tabla B-7: Precisión, sensibilidad y especificidad clasificador PSOHMM (Estados: 5, Gaussianas: 16)

Técnica de Descomposición	Clasificador -> Promedio ± Desviación Estándar (Varianza)								
	Análisis de Relevancia			Normalización Señal: Bipolar, Normalización Matriz Característica: Unipolar			Normalización Señal: Unipolar, Normalización Matriz Característica: Unipolar		
	PCA	FRS	SFFS	Precisión (%)	Sensibilidad	Especificidad	Precisión (%)	Sensibilidad	Especificidad
HVD	Si	No	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
HVD	No	Si	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
HVD	No	No	Si	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
EMDv3	Si	No	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
EMDv3	No	Si	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
EMDv3	No	No	Si	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)

fastEMD	Si	No	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
fastEMD	No	Si	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
fastEMD	No	No	Si	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
EEMDv2	Si	No	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
EEMDv2	No	Si	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
EEMDv2	No	No	Si	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
EEMDv1	Si	No	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
EEMDv1	No	Si	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
EEMDv1	No	No	Si	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
CEEMDANv1	Si	No	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
CEEMDANv1	No	Si	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
CEEMDANv1	No	No	Si	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
CEEMDANv2	Si	No	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
CEEMDANv2	No	Si	No	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)
CEEMDANv2	No	No	Si	97.00 ± 1.38 (0.02)	0.96 ± 0.02 (0.00)	0.98 ± 0.02 (0.00)	78.11 ± 19.25 (3.70)	0.79 ± 0.17 (0.03)	0.77 ± 0.22 (0.05)

Tabla B-8: Precisión, sensibilidad y especificidad clasificador HMM (Estados: 10, Gaussianas: 7)

Técnica de Descomposición	Clasificador -> Promedio ± Desviación Estándar (Varianza)					
	Normalización Señal: Bipolar, Normalización Matriz Característica: Unipolar			Normalización Señal: Unipolar, Normalización Matriz Característica: Unipolar		
	Precisión (%)	Sensibilidad	Especificidad	Precisión (%)	Sensibilidad	Especificidad
HVD	94.89 ± 1.53 (0.02)	0.94 ± 0.02 (0.00)	0.96 ± 0.02 (0.00)	92.56 ± 2.80 (0.08)	0.91 ± 0.04 (0.00)	0.94 ± 0.03 (0.00)
EMDv3	92.81 ± 2.19 (0.05)	0.90 ± 0.04 (0.00)	0.95 ± 0.02 (0.00)	90.38 ± 3.70 (0.14)	0.89 ± 0.05 (0.00)	0.92 ± 0.04 (0.00)
fastEMD	93.47 ± 1.74 (0.03)	0.92 ± 0.02 (0.00)	0.95 ± 0.02 (0.00)	91.34 ± 3.28 (0.11)	0.90 ± 0.04 (0.00)	0.93 ± 0.04 (0.00)
EEMDv2	50.00 ± 0.00 (0.00)	0.50 ± 0.00 (0.00)	0.50 ± 0.00 (0.00)	83.53 ± 19.56 (3.83)	0.84 ± 0.20 (0.04)	0.83 ± 0.20 (0.04)
EEMDv1	88.39 ± 2.41 (0.06)	0.88 ± 0.04 (0.00)	0.89 ± 0.04 (0.00)	85.58 ± 3.91 (0.15)	0.84 ± 0.05 (0.00)	0.87 ± 0.05 (0.00)
CEEMDANv1	88.58 ± 2.54 (0.06)	0.87 ± 0.05 (0.00)	0.90 ± 0.04 (0.00)	86.44 ± 3.33 (0.11)	0.85 ± 0.05 (0.00)	0.87 ± 0.05 (0.00)
CEEMDANv2	96.69 ± 1.41 (0.02)	0.95 ± 0.03 (0.00)	0.98 ± 0.02 (0.00)	94.63 ± 2.43 (0.06)	0.93 ± 0.03 (0.00)	0.96 ± 0.04 (0.00)

Tabla B-9: Precisión, sensibilidad y especificidad clasificador PSOHMM (Estados: 10, Gaussianas: 7)

Técnica de Descomposición	Clasificador -> Promedio ± Desviación Estándar (Varianza)					
	Normalización Señal: Bipolar, Normalización Matriz Característica: Unipolar			Normalización Señal: Unipolar, Normalización Matriz Característica: Unipolar		
	Precisión (%)	Sensibilidad	Especificidad	Precisión (%)	Sensibilidad	Especificidad
HVD	85.44 ± 12.74 (1.62)	0.81 ± 0.28 (0.08)	0.90 ± 0.07 (0.01)	83.85 ± 8.81 (0.78)	0.81 ± 0.18 (0.03)	0.87 ± 0.08 (0.01)
EMDv3	86.25 ± 4.40 (0.19)	0.81 ± 0.09 (0.01)	0.91 ± 0.07 (0.01)	82.13 ± 6.28 (0.39)	0.78 ± 0.10 (0.01)	0.86 ± 0.09 (0.01)
fastEMD	86.75 ± 7.85 (0.62)	0.82 ± 0.17 (0.03)	0.92 ± 0.05 (0.00)	83.39 ± 7.79 (0.61)	0.81 ± 0.14 (0.02)	0.86 ± 0.11 (0.01)
EEMDv2	93.58 ± 2.32 (0.05)	0.93 ± 0.05 (0.00)	0.94 ± 0.04 (0.00)	88.56 ± 6.60 (0.44)	0.87 ± 0.10 (0.01)	0.90 ± 0.07 (0.00)
EEMDv1	75.36 ± 6.91 (0.48)	0.72 ± 0.11 (0.01)	0.79 ± 0.09 (0.01)	74.73 ± 6.87 (0.47)	0.72 ± 0.14 (0.02)	0.78 ± 0.09 (0.01)
CEEMDANv1	81.17 ± 8.44 (0.71)	0.78 ± 0.19 (0.03)	0.85 ± 0.08 (0.01)	80.22 ± 7.17 (0.51)	0.80 ± 0.14 (0.02)	0.81 ± 0.11 (0.01)
CEEMDANv2	92.17 ± 3.81 (0.14)	0.91 ± 0.07 (0.00)	0.94 ± 0.06 (0.00)	88.10 ± 6.36 (0.40)	0.86 ± 0.10 (0.01)	0.90 ± 0.08 (0.01)

La Tabla B-10 presenta los tiempos promedios (en segundos), la desviación estándar y la varianza, calculados a partir de los tiempos de entrenamiento en base a los resultados generados con la validación cruzada 70-30 (70 % de las señales disponibles, es decir, 140 señales Normales y 140 señales con Sople para 30 repeticiones).

Tabla B-10: Tiempo (seg) de entrenamiento de los clasificadores implementados en la etapa experimental.

<i>Técnica Descomposición</i>	Análisis de Relevancia			Clasificador -> Promedio ± Desviación Estándar (Varianza)			
	PCA	FRS	SFFS	HMM	Naive Bayes	KNN	PSOHMM
HVD	Si	No	No	1855.23 ±	893.54 ±	893.54 ±	28.14 ±
				243.47	121.46	121.46	4.37
HVD	No	Si	No	(59276.44)	(14753.08)	(14753.08)	(19.10)
				585.34 ±	893.54 ±	893.54 ±	16.05 ±
HVD	No	No	Si	133.95	121.46	121.46	2.20 (4.84)
				(17942.68)	(14753.08)	(14753.08)	
HVD	No	No	Si	1109.67 ±	893.54 ±	893.54 ±	19.52 ±
				689.24	121.46	121.46	7.50
EMDv3	Si	No	No	(475056.19)	(14753.08)	(14753.08)	(56.18)
				1528.11 ±	893.54 ±	893.54 ±	31.78 ±
EMDv3	No	Si	No	149.91	121.46	121.46	4.10
				(22474.41)	(14753.08)	(14753.08)	(16.79)
EMDv3	No	No	Si	1047.43 ±	893.54 ±	893.54 ±	25.80 ±
				187.92	121.46	121.46	7.14
EMDv3	No	No	Si	(35315.33)	(14753.08)	(14753.08)	(50.97)
				1181.44 ±	893.54 ±	893.54 ±	18.44 ±
fastEMD	Si	No	No	1300.88	121.46	121.46	6.52
				(1692295.80)	(14753.08)	(14753.08)	(42.56)
fastEMD	No	Si	No	1500.61 ±	893.54 ±	893.54 ±	31.29 ±
				165.17	121.46	121.46	11.14
fastEMD	No	No	Si	(27281.95)	(14753.08)	(14753.08)	(124.18)
				590.73 ±	893.54 ±	893.54 ±	17.81 ±
fastEMD	No	No	Si	123.51	121.46	121.46	2.61 (6.79)
				(15255.55)	(14753.08)	(14753.08)	
fastEMD	No	No	Si	960.45 ±	893.54 ±	893.54 ±	21.33 ±
				589.69	121.46	121.46	11.10
EEMDv2	Si	No	No	(347733.38)	(14753.08)	(14753.08)	(123.13)
				1606.12 ±	893.54 ±	893.54 ±	31.39 ±
EEMDv2	No	Si	No	625.82	121.46	121.46	6.49
				(391646.94)	(14753.08)	(14753.08)	(42.07)
EEMDv2	No	No	Si	552.42 ±	893.54 ±	893.54 ±	16.15 ±
				1050.73	121.46	121.46	1.61 (2.59)
EEMDv2	No	No	Si	(1104023.32)	(14753.08)	(14753.08)	
				814.72 ±	893.54 ±	893.54 ±	18.10 ±
EEMDv2	No	No	Si	69.50	121.46	121.46	7.83
				(4830.01)	(14753.08)	(14753.08)	(61.29)

EEMDv1	Si	No	No	1500.57 ±	893.54 ±	893.54 ±	27.38 ±
				122.32	121.46	121.46	4.37
				(14961.05)	(14753.08)	(14753.08)	(19.09)
EEMDv1	No	Si	No	1083.43 ±	893.54 ±	893.54 ±	27.92 ±
				685.77	121.46	121.46	8.82
				(470284.74)	(14753.08)	(14753.08)	(77.73)
EEMDv1	No	No	Si	843.95 ±	893.54 ±	893.54 ±	18.88 ±
				96.03	121.46	121.46	7.34
				(9221.64)	(14753.08)	(14753.08)	(53.83)
CEEMDANv1	Si	No	No	1492.38 ±	893.54 ±	893.54 ±	31.41 ±
				187.41	121.46	121.46	6.71
				(35120.77)	(14753.08)	(14753.08)	(45.02)
CEEMDANv1	No	Si	No	300.57 ±	893.54 ±	893.54 ±	24.67 ±
				112.73	121.46	121.46	10.74
				(12709.00)	(14753.08)	(14753.08)	(115.30)
CEEMDANv1	No	No	Si	1018.47 ±	893.54 ±	893.54 ±	18.39 ±
				640.33	121.46	121.46	5.58
				(410023.00)	(14753.08)	(14753.08)	(31.15)
CEEMDANv2	Si	No	No	2098.67 ±	893.54 ±	893.54 ±	31.70 ±
				1567.75	121.46	121.46	9.56
				(2457833.79)	(14753.08)	(14753.08)	(91.34)
CEEMDANv2	No	Si	No	408.05 ±	893.54 ±	893.54 ±	15.21 ±
				123.42	121.46	121.46	6.39
				(15232.55)	(14753.08)	(14753.08)	(40.79)
CEEMDANv2	No	No	Si	893.54 ±	893.54 ±	893.54 ±	20.45 ±
				121.46	121.46	121.46	8.83
				(14753.08)	(14753.08)	(14753.08)	(77.95)

En las Figura B-1 a Figura B-6 se aprecian la precisión (*ACC*) y el área bajo la curva (*AUC*) como el promedio de la validación de 60 señales PCG, a partir de dos redes HMM (red Normal y Soplo) entrenadas con una matriz de características de 140 señales con normalización bipolar del constructo de la señal y normalización unipolar de la matriz de características.

Figura B-1: Curva ROC clasificador HMM con matriz característica reducida a partir de PCA (normalización señal: bipolar, normalización matriz característica: unipolar).

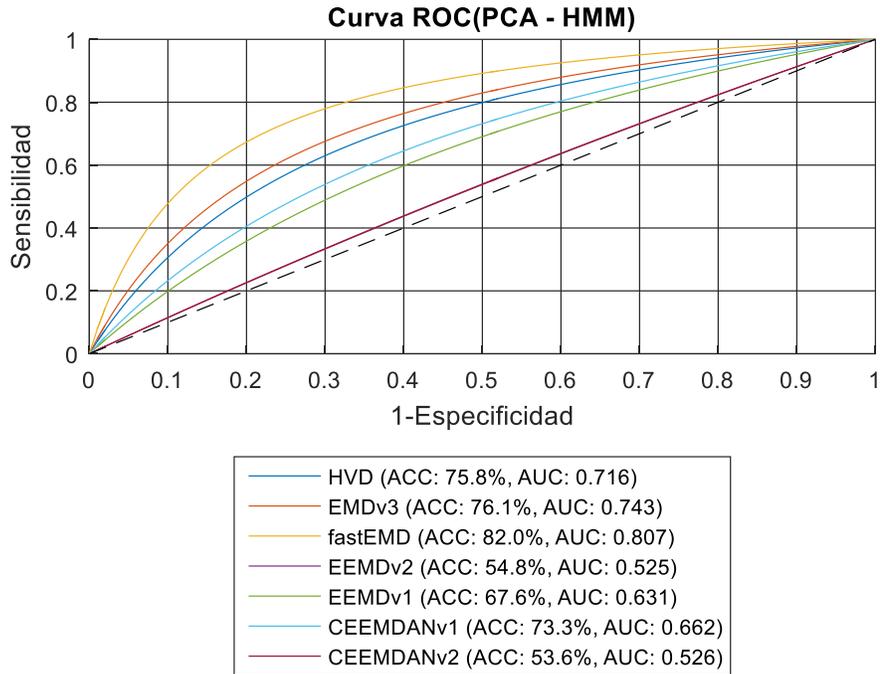


Figura B-2: Curva ROC clasificador PSOHMM con matriz característica reducida a partir de PCA (normalización señal: bipolar, normalización matriz característica: unipolar).

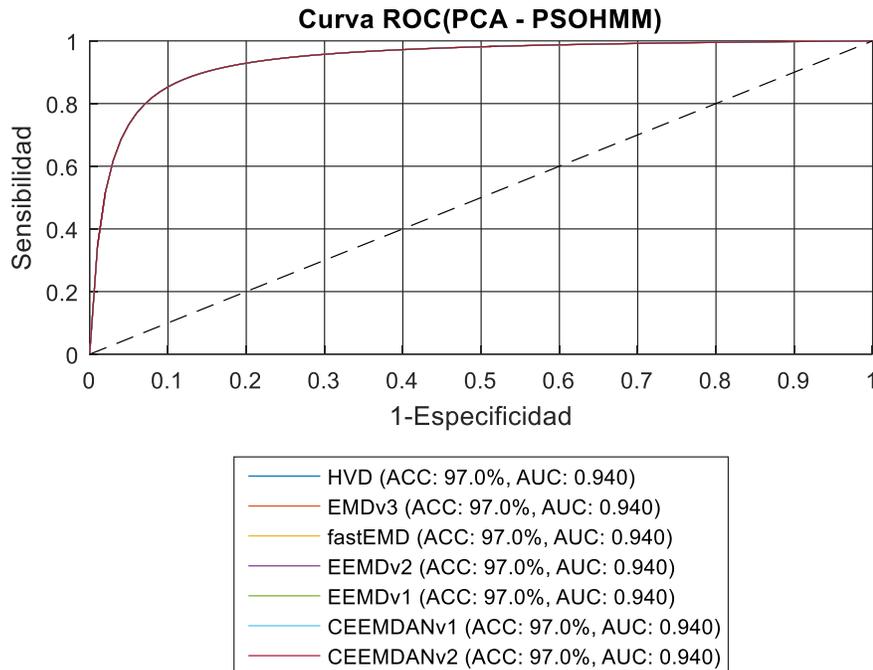


Figura B-3: Curva ROC clasificador HMM con matriz característica reducida a partir de FRS (normalización señal: bipolar, normalización matriz característica: unipolar).

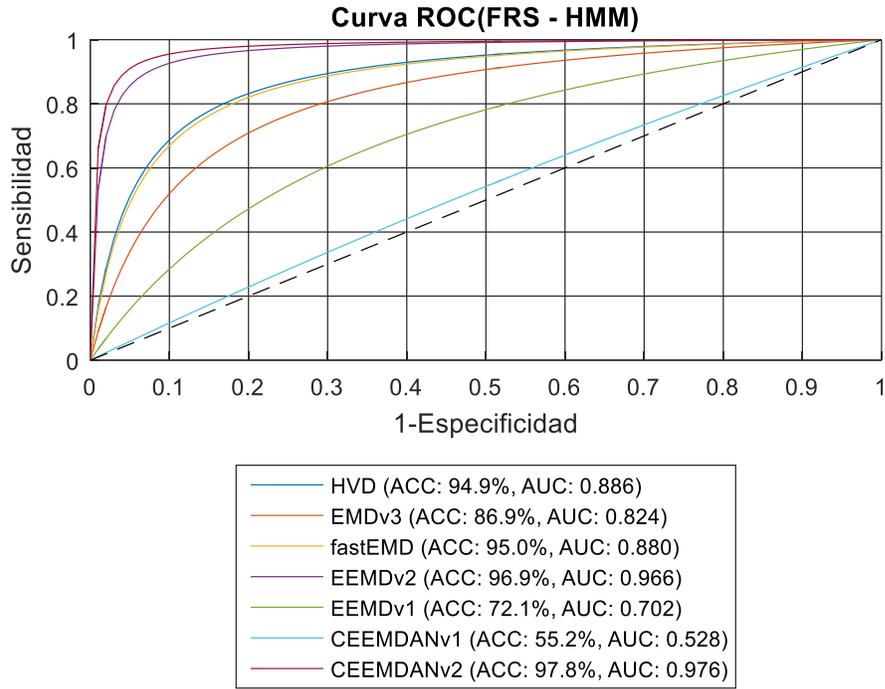


Figura B-4: Curva ROC clasificador PSOHMM con matriz característica reducida a partir de FRS (normalización señal: bipolar, normalización matriz característica: unipolar).

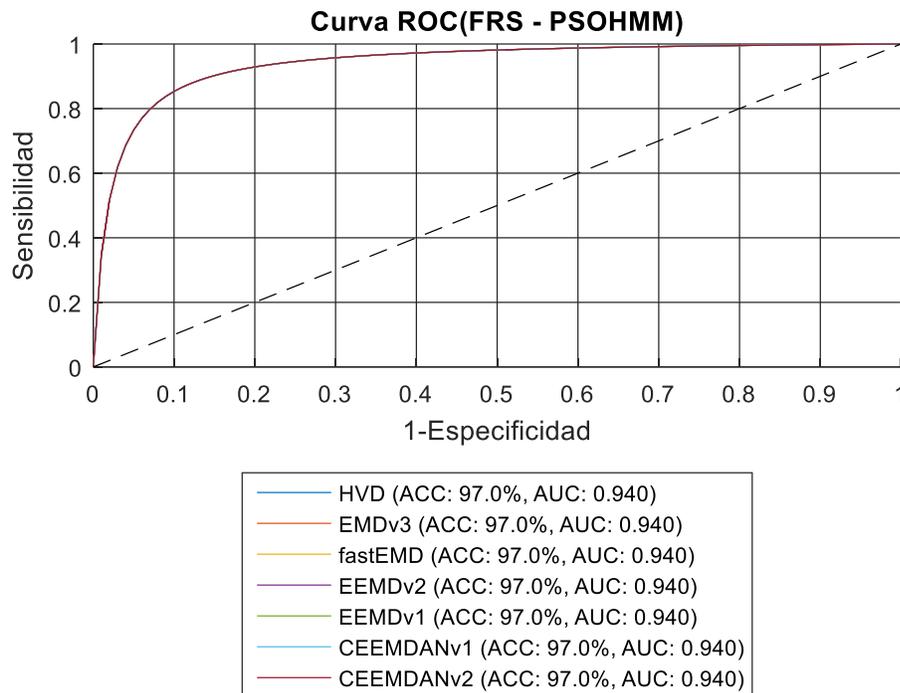


Figura B-5: Curva ROC clasificador HMM con matriz característica reducida a partir de SFFS (normalización señal: bipolar, normalización matriz característica: unipolar).

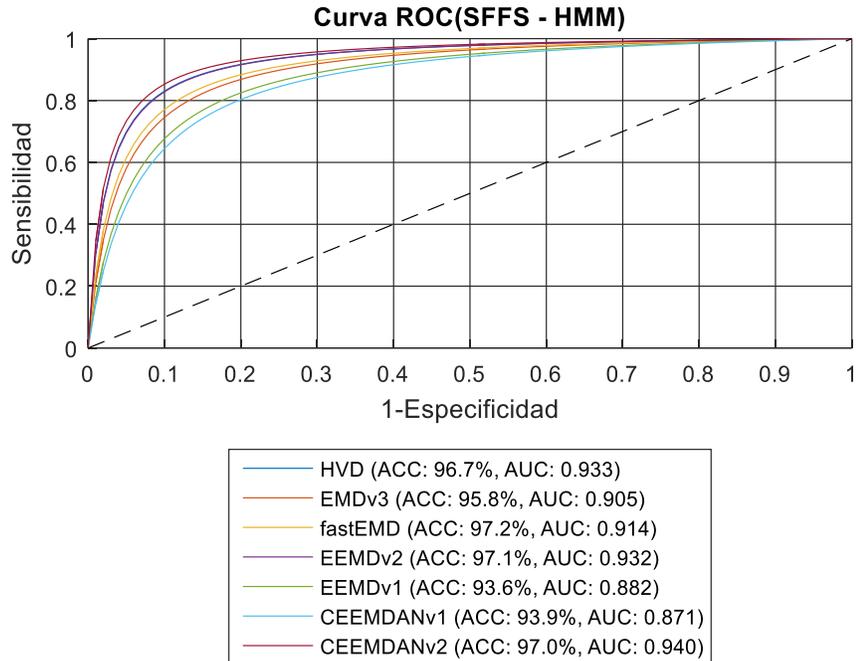
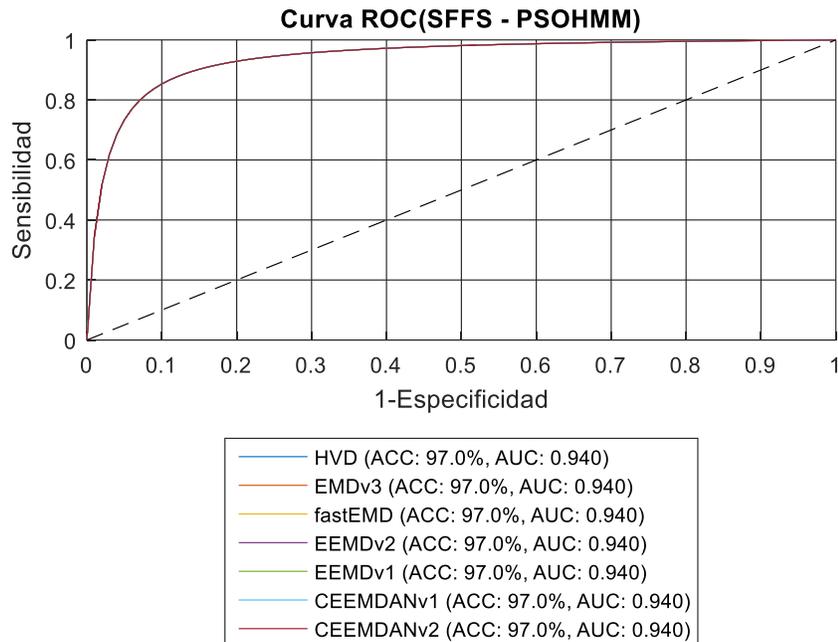


Figura B-6: Curva ROC clasificador PSOHMM con matriz característica reducida a partir de SFFS (normalización señal: bipolar, normalización matriz característica: unipolar).



En las Figura B-7 a **Figura B-12** se aprecian la precisión (ACC) y el área bajo la curva (AUC) como el promedio de la validación de 60 señales PCG, a partir de dos redes HMM (red Normal y Soplo) entrenadas con 140 señales a partir de una matriz características con normalización unipolar del constructo de la señal PCG y normalización unipolar de la matriz de características.

Figura B-7: Curva ROC clasificador HMM con matriz característica reducida a partir de PCA (normalización señal: unipolar, normalización matriz característica: unipolar)

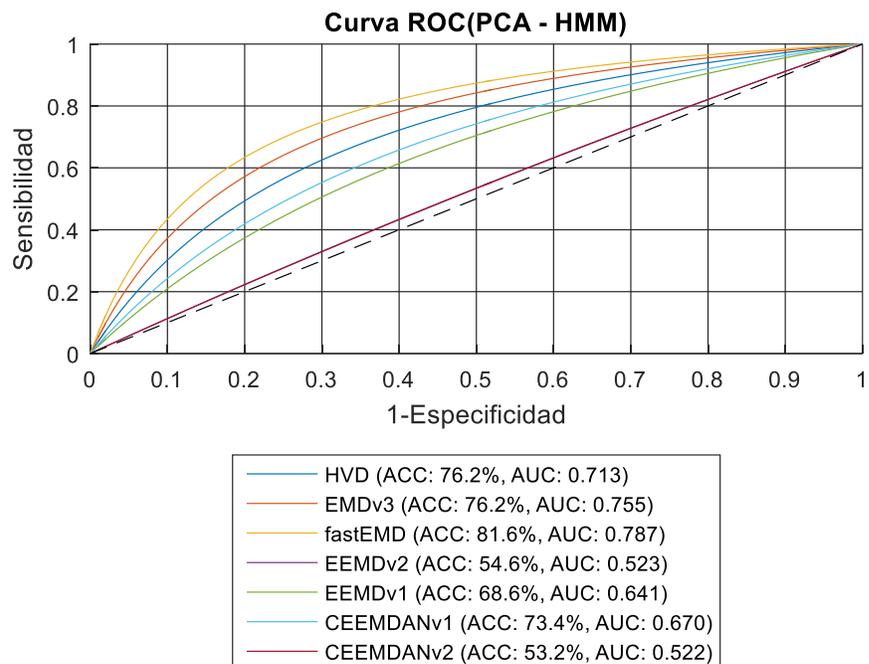


Figura B-8: Curva ROC clasificador PSOHMM con matriz característica reducida a partir de PCA (normalización señal: unipolar, normalización matriz característica: unipolar).

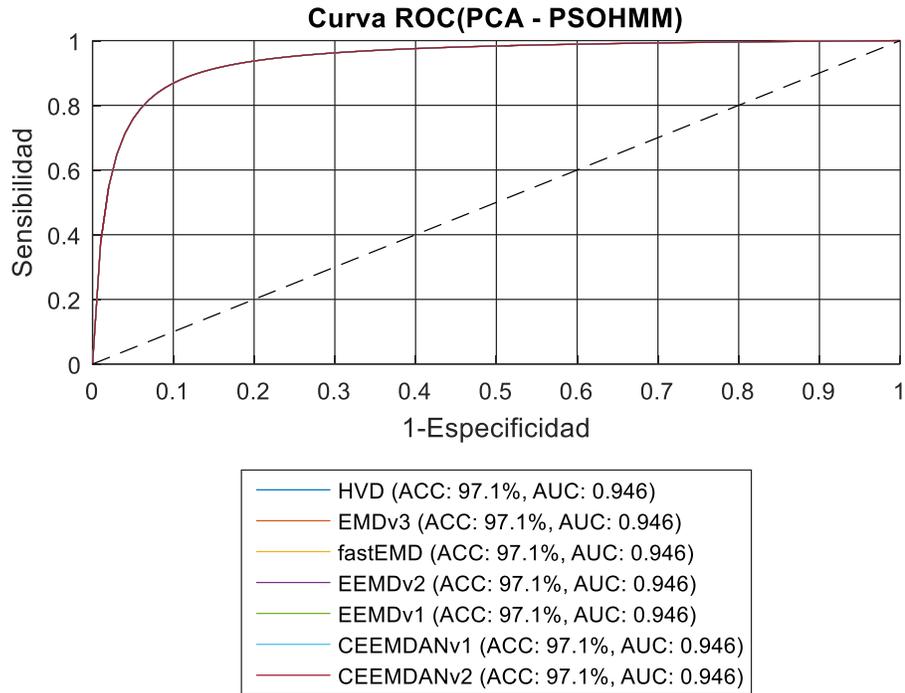


Figura B-9: Curva ROC clasificador HMM con matriz característica reducida a partir de FRS (normalización señal: unipolar, normalización matriz característica: unipolar).

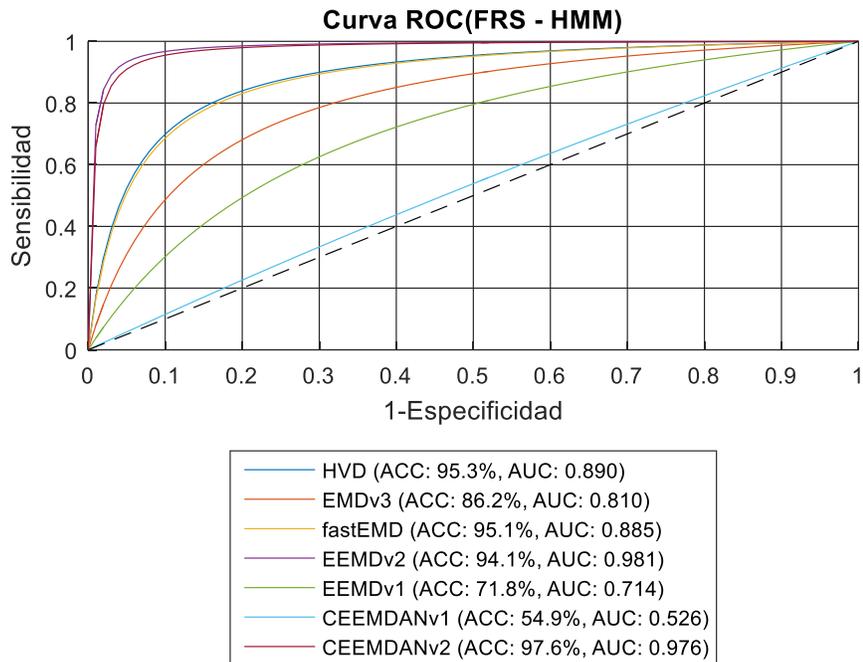


Figura B-10: Curva ROC clasificador PSOHMM con matriz característica reducida con FRS (normalización señal: unipolar, normalización matriz característica: unipolar).

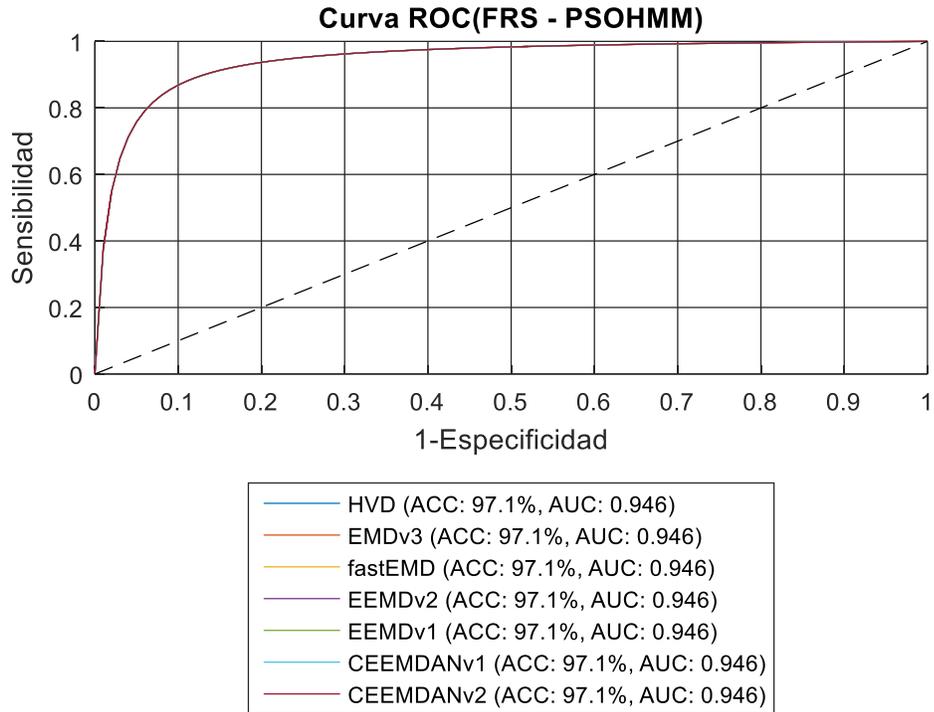


Figura B-11: Curva ROC clasificador HMM con matriz característica reducida a partir de SFFS (normalización señal: unipolar, normalización matriz característica: unipolar).

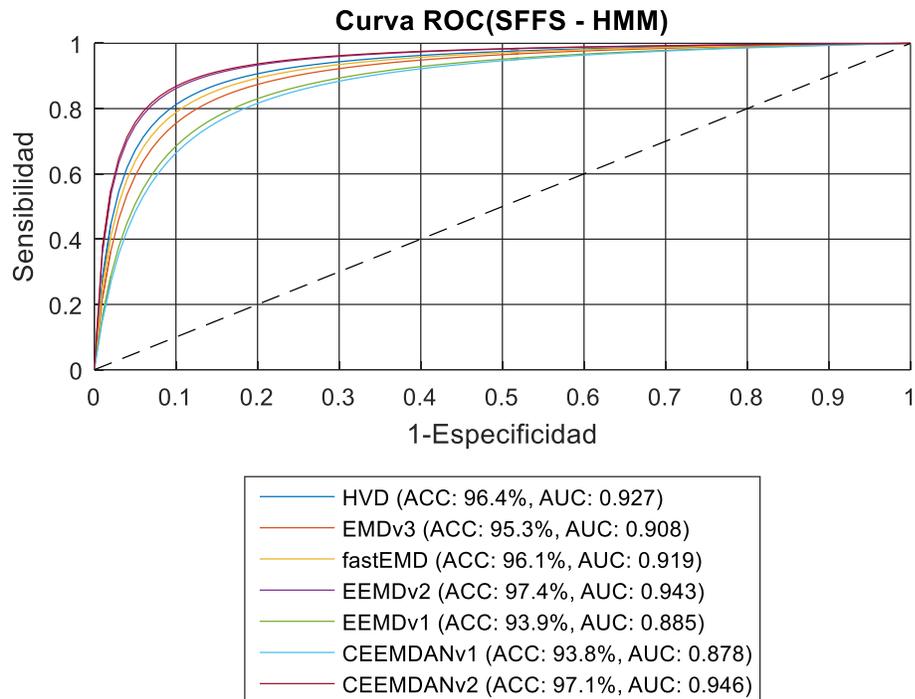
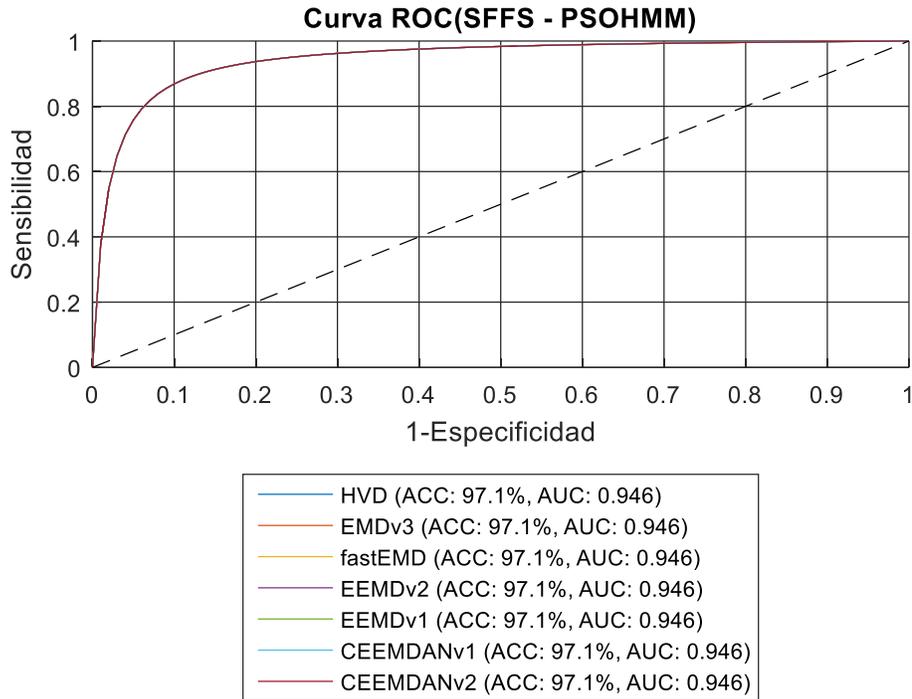


Figura B-12: Curva ROC clasificador PSOHMM con matriz característica reducida con SFFS (normalización señal: unipolar, normalización matriz característica: unipolar).



En las Figura B-13 a la **Figura B-24**, se pueden apreciar los diagramas de bigotes generados con los datos arrojados por el clasificador HMM, a partir de las características obtenidas con las diferentes técnicas de análisis de relevancia implementadas.

Se puede establecer en las diferentes pruebas realizadas, que los resultados obtenidos con el clasificador HMM son muy similares ya que los valores máximos y mínimos son muy cercanos (bajo la misma configuración de normalización de los constructos de la señal PCG y normalización de la matriz de características).

Figura B-13: Diagramas de bigotes clasificador HMM (normalización de la señal: bipolar y normalización matriz característica: unipolar reducida a partir de PCA)

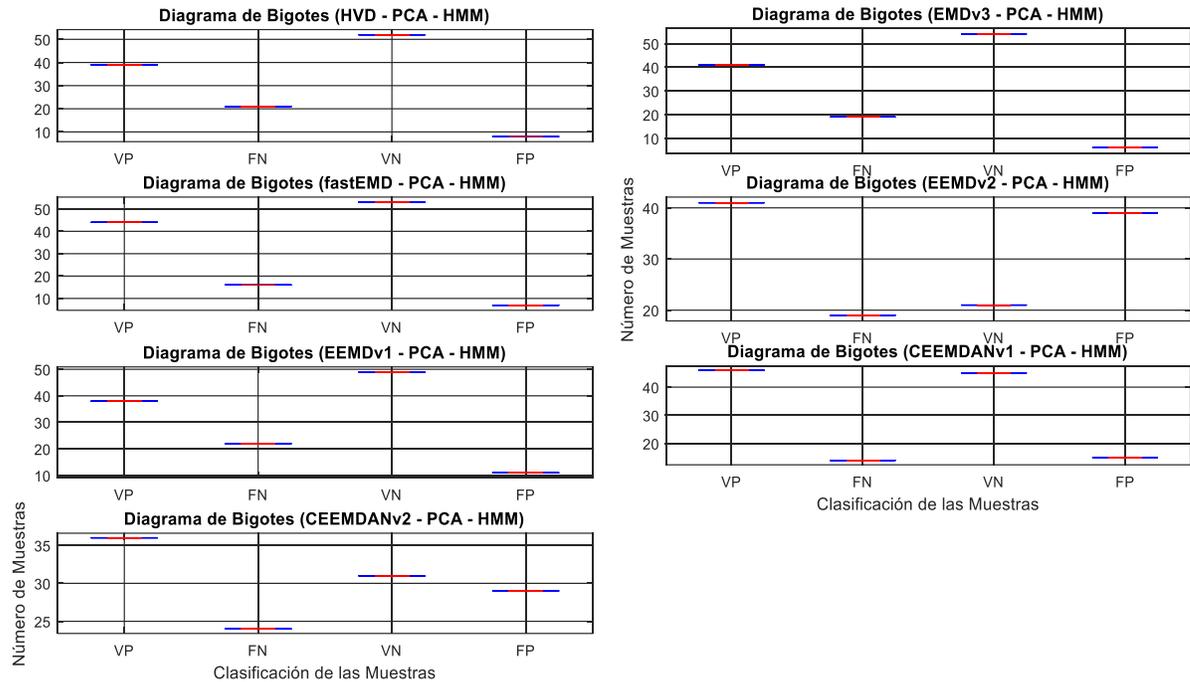


Figura B-14: Diagramas de bigotes clasificador PSOHMM (normalización señal: bipolar y normalización matriz característica: unipolar reducida a partir de PCA)

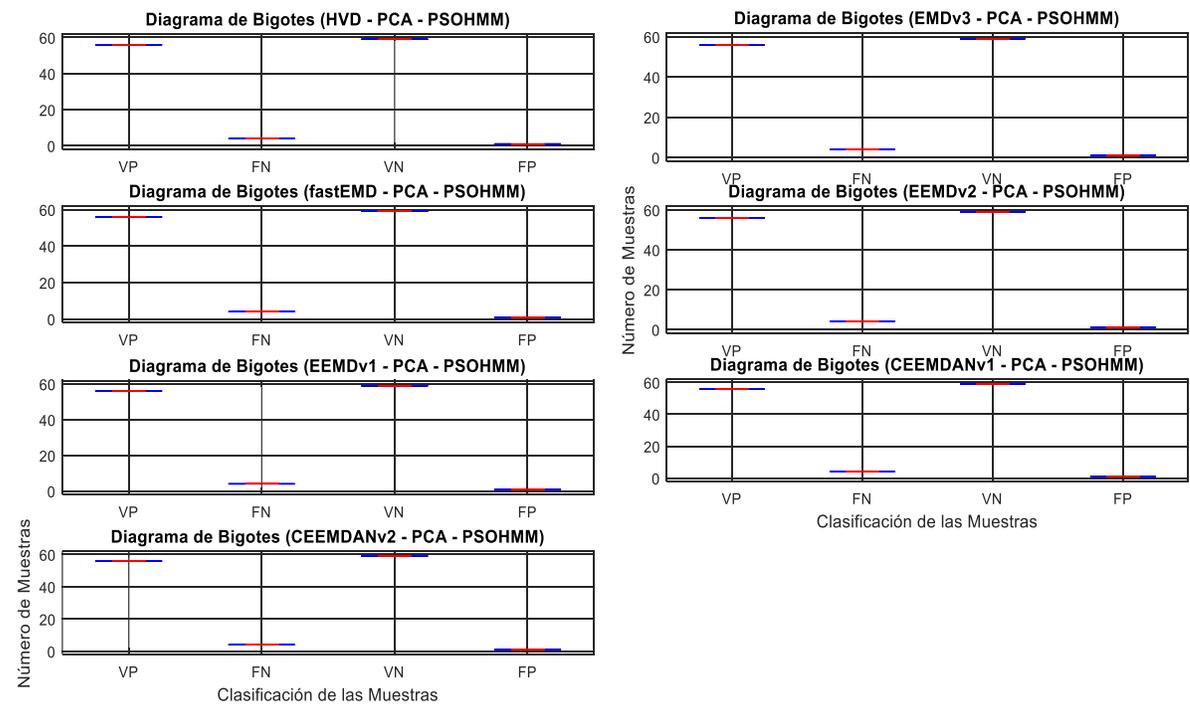


Figura B-15: Diagramas de bigotes clasificador HMM (normalización señal: bipolar y normalización matriz característica: unipolar reducida a partir de FRS)

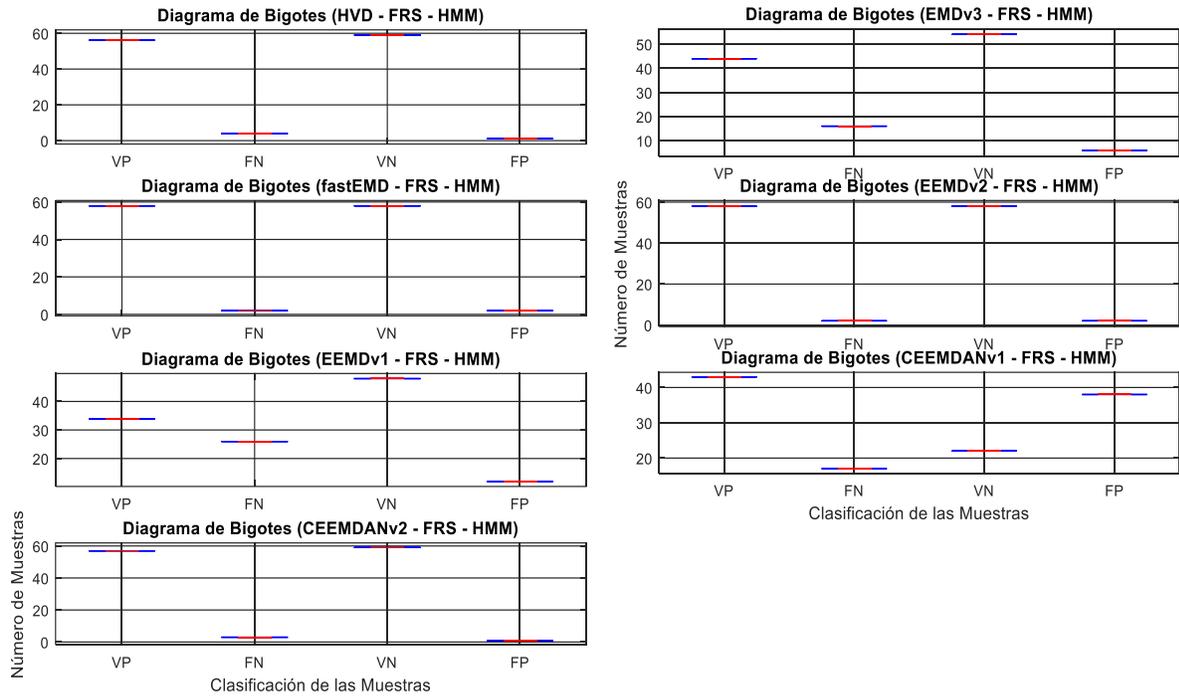


Figura B-16: Diagramas de bigotes clasificador PSOHMM (normalización señal: bipolar y normalización matriz característica: unipolar reducida a partir de FRS)

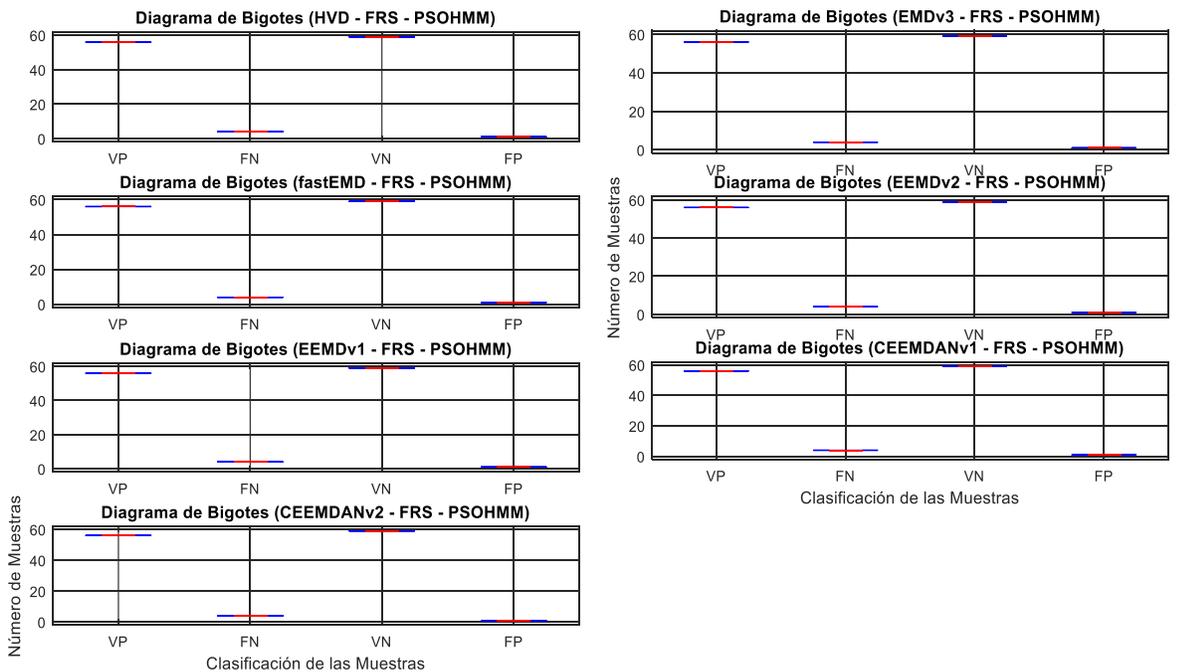


Figura B-17: Diagramas de bigotes clasificador HMM (normalización señal: bipolar y normalización matriz característica: unipolar reducida a partir de SFFS)

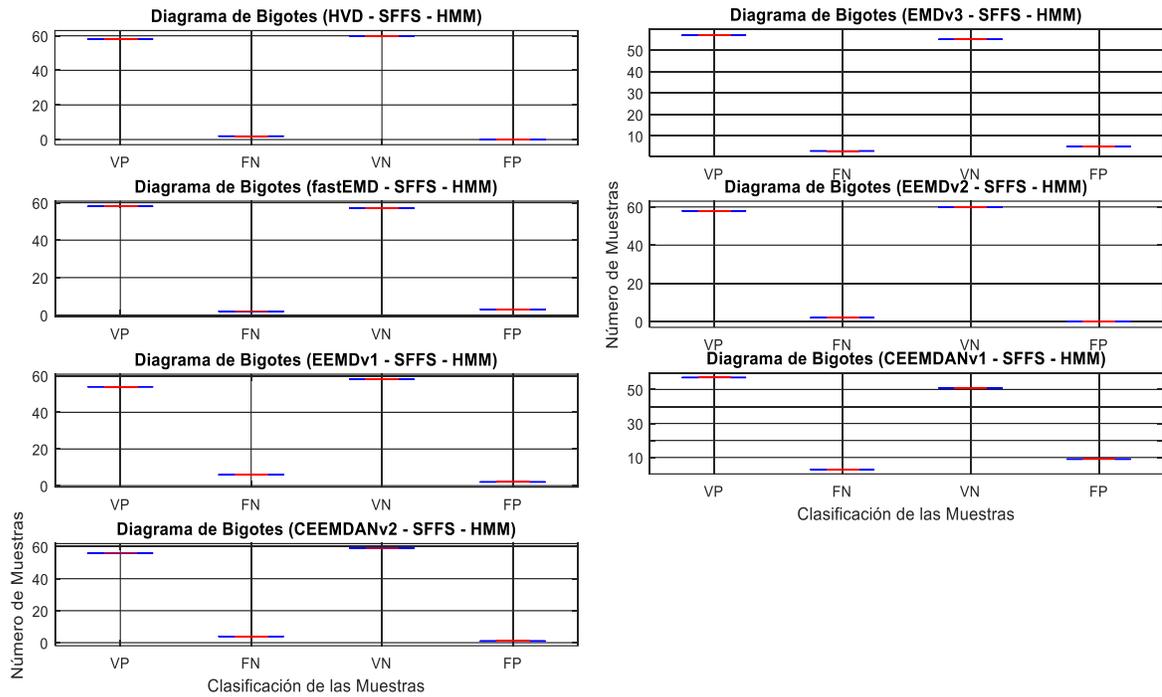


Figura B-18: Diagramas de bigotes clasificador PSOHMM (normalización señal: bipolar y normalización matriz característica: unipolar reducida a partir de SFFS)

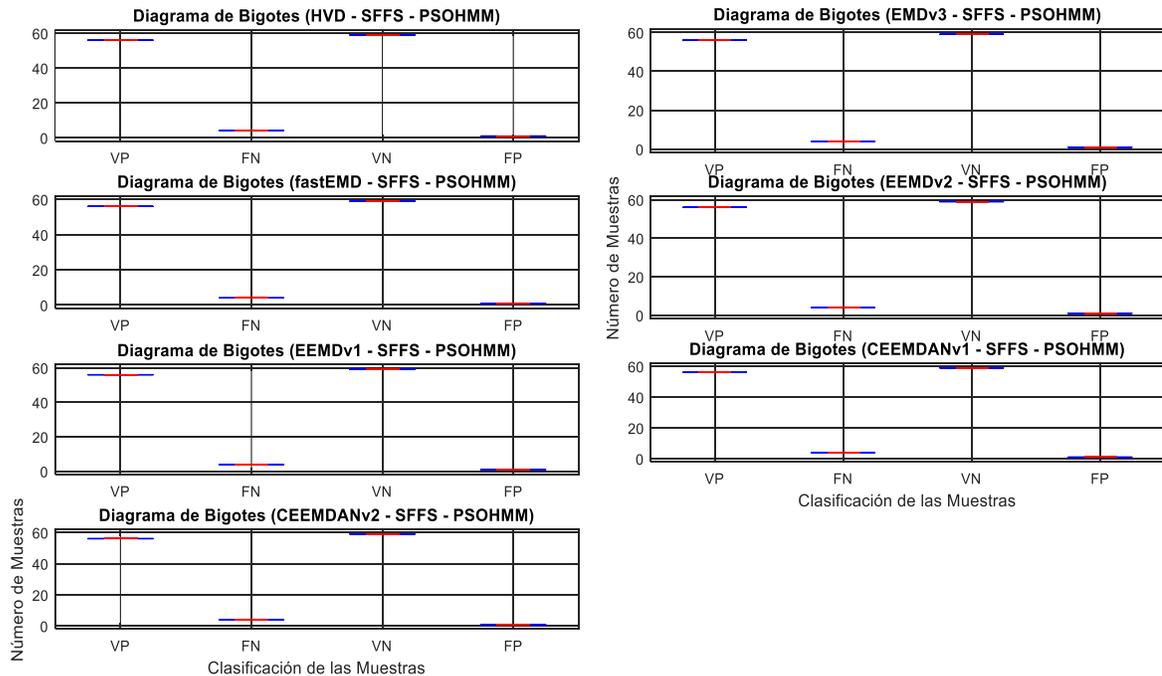


Figura B-19: Diagramas de bigotes clasificador HMM (normalización señal: unipolar y normalización matriz característica: unipolar reducida a partir de PCA)

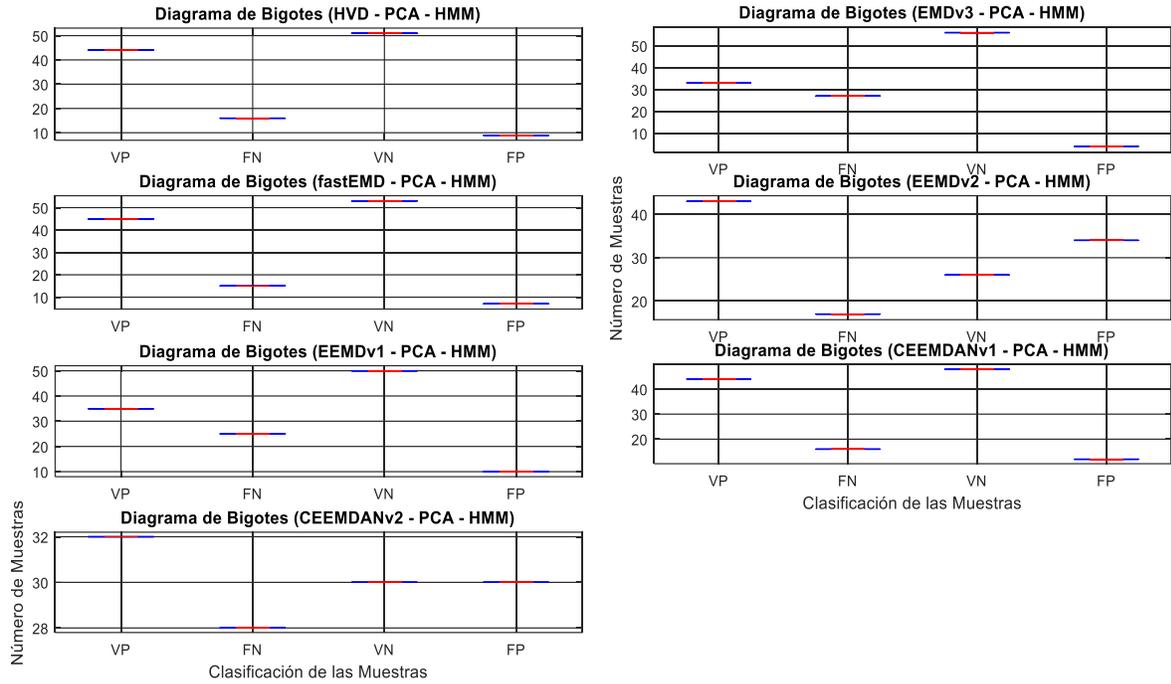


Figura B-20: Diagramas de bigotes clasificador PSOHMM (normalización señal: unipolar y normalización matriz característica: unipolar reducida a partir de PCA)

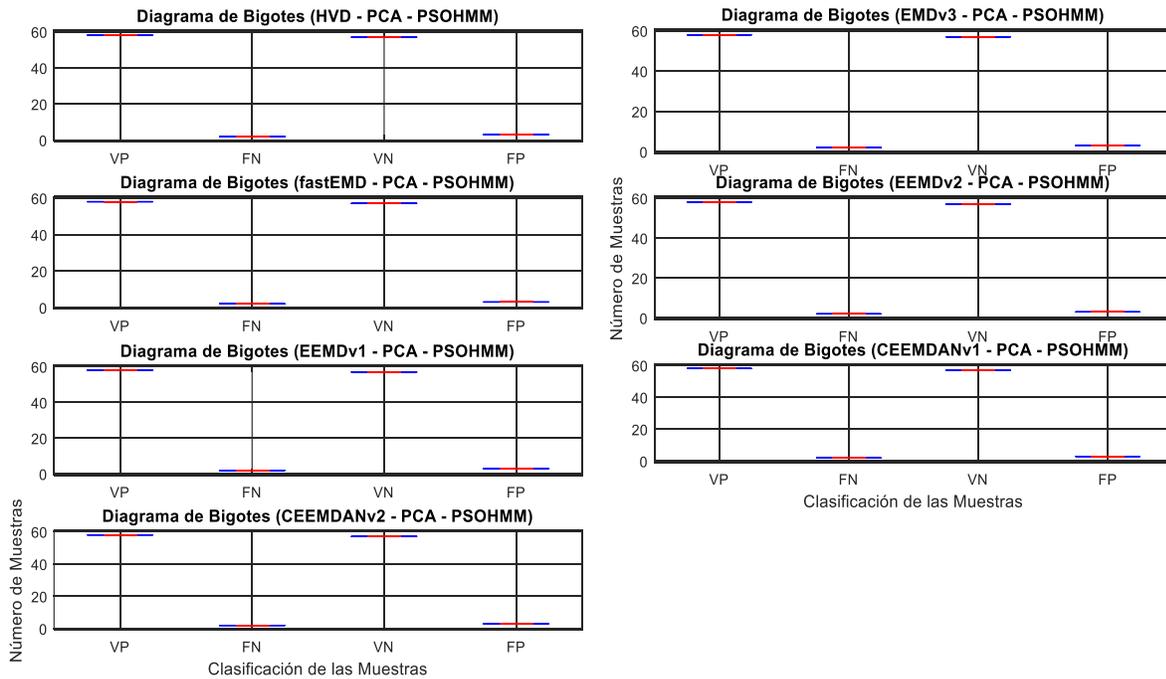


Figura B-21: Diagramas de bigotes clasificador HMM (normalización señal: unipolar y normalización matriz característica: unipolar reducida a partir de FRS).

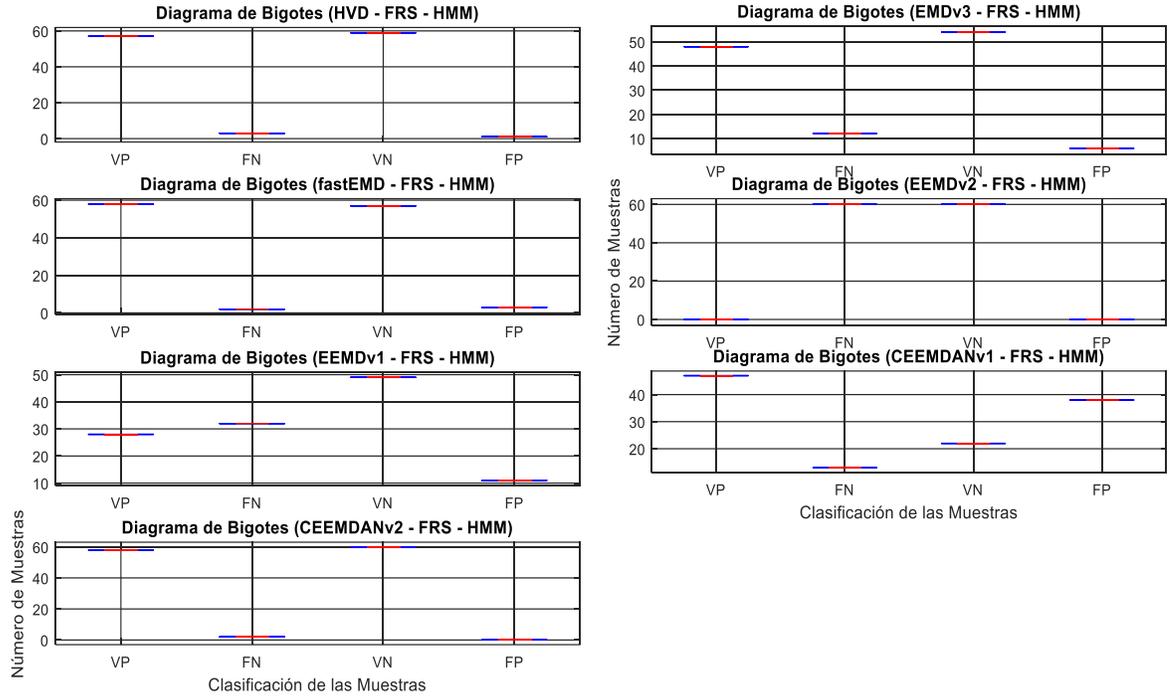


Figura B-22: Diagramas de bigotes clasificador PSOHMM (normalización señal: unipolar y normalización matriz característica: unipolar reducida a partir de FRS).

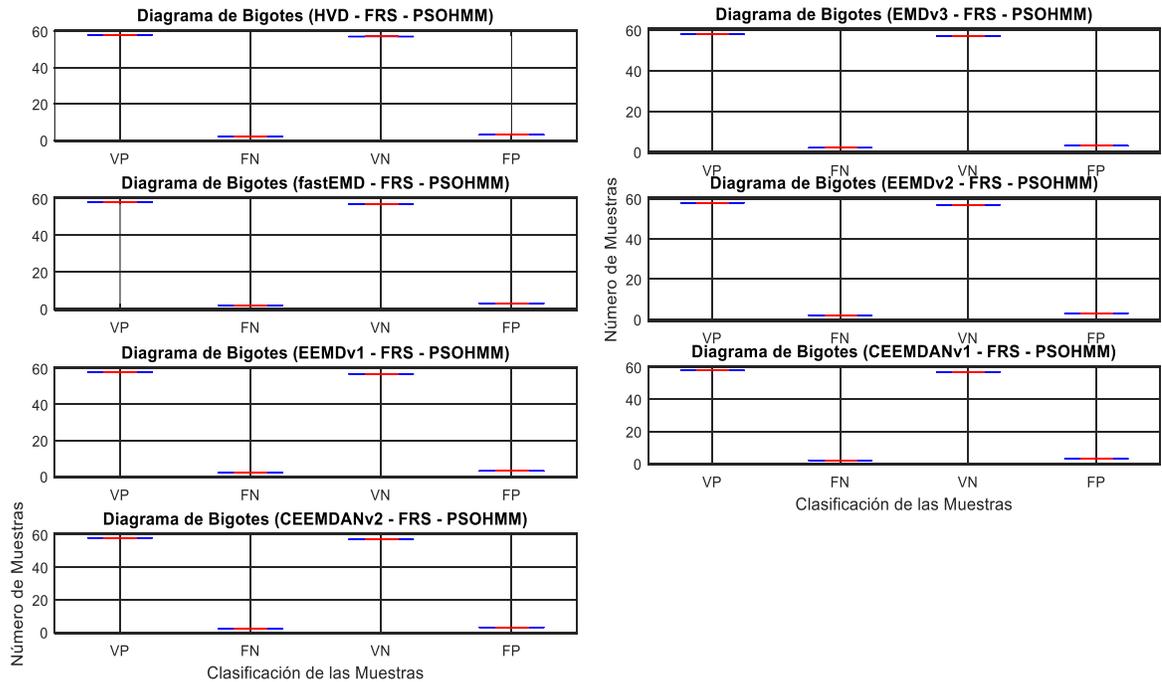


Figura B-23: Diagramas de bigotes clasificador HMM (normalización señal: unipolar y normalización matriz característica: unipolar reducida a partir de SFFS).

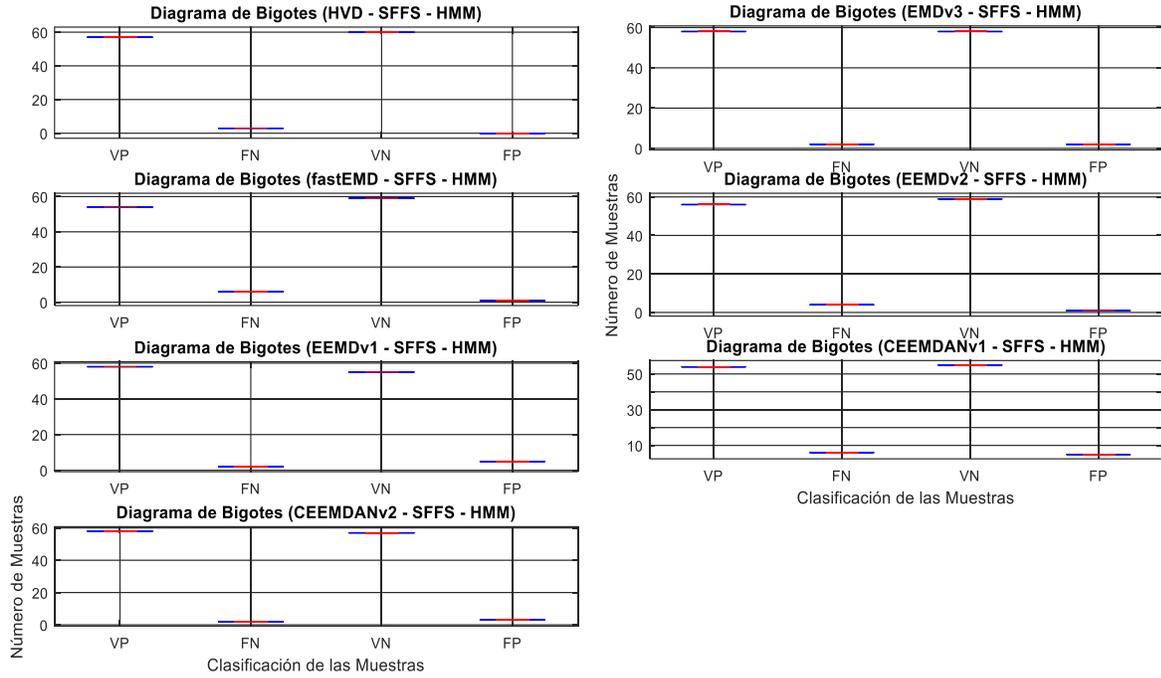
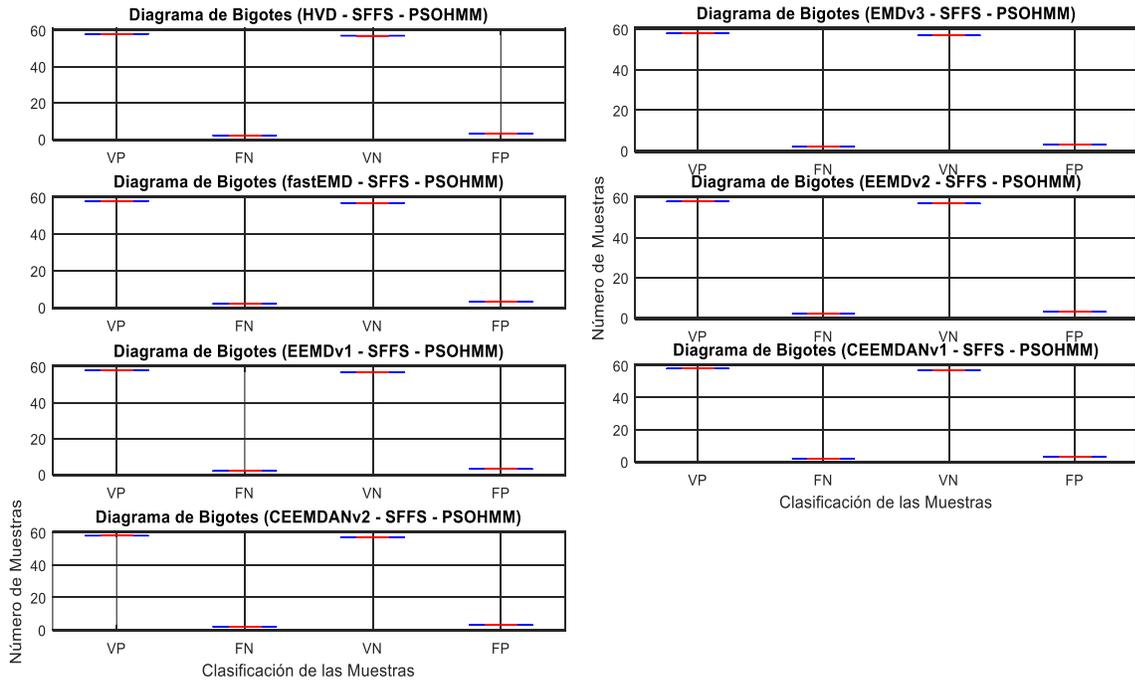


Figura B-24: Diagramas de bigotes clasificador PSOHMM (normalización señal: unipolar y normalización matriz característica: unipolar reducida a partir de SFFS).



En las Figura B-25 a la Figura B-45 se pueden apreciar los diagramas de bigotes construidos con los resultados obtenidos de las validaciones de los diferentes clasificadores utilizados en las pruebas experimentales. Teniendo como referencia la técnica de descomposición utilizada en la generación de la matriz de características y el algoritmo de relevancia, sin discriminar por el tipo de pre-normalización ni la post-normalización empleada.

Figura B-25: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición HVD y el análisis de relevancia PCA).

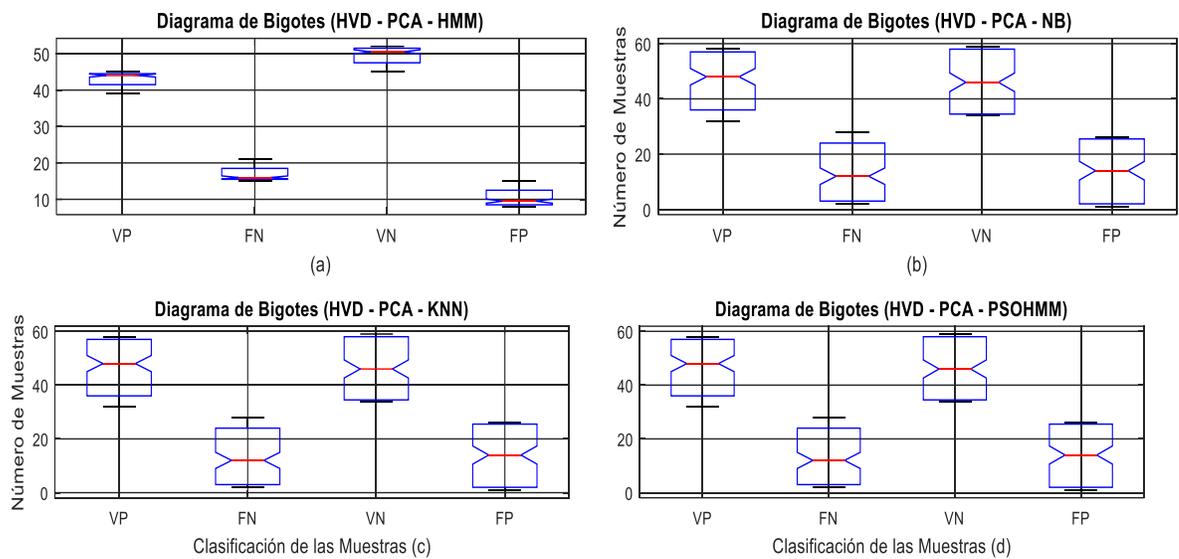


Figura B-26: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición HVD y el análisis de relevancia FRS).

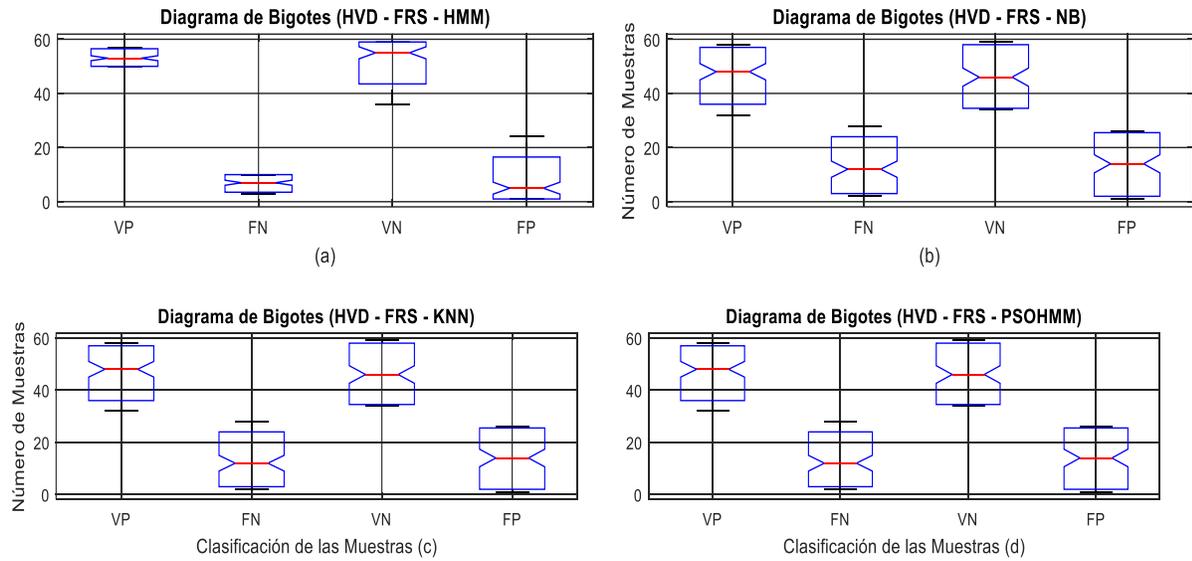


Figura B-27: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición HVD y el análisis de relevancia SFFS).

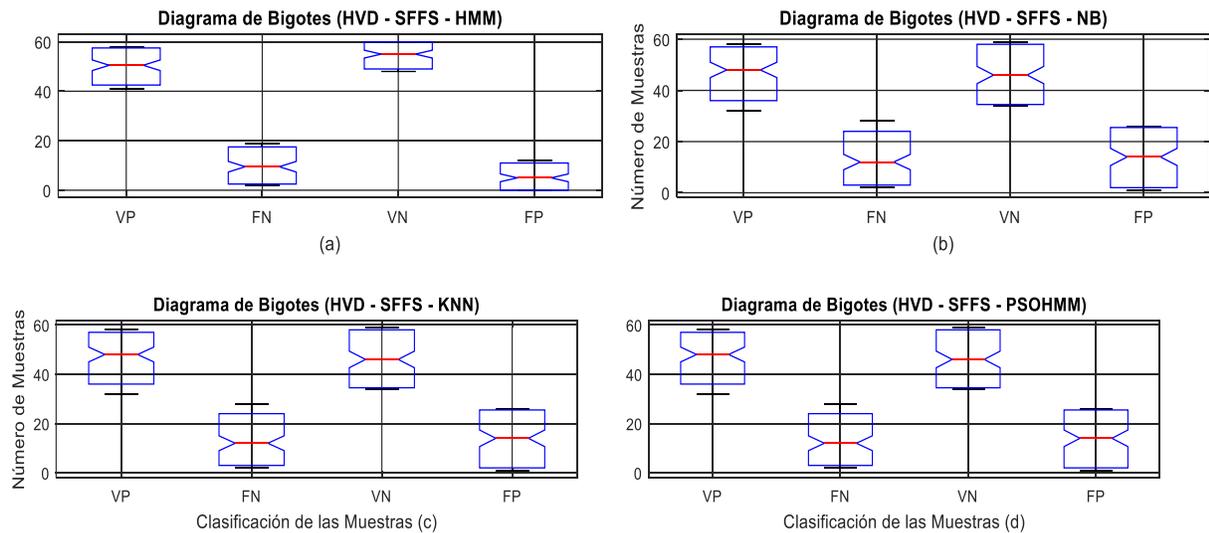


Figura B-28: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EMDv3 y el análisis de relevancia PCA).

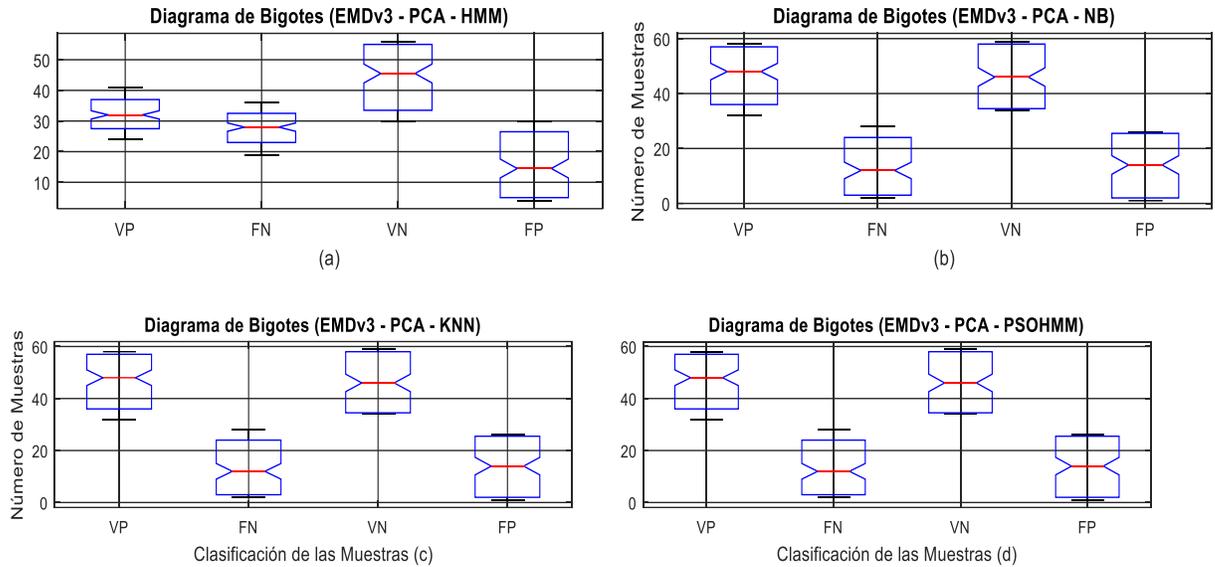


Figura B-29: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EMDv3 y el análisis de relevancia FRS).

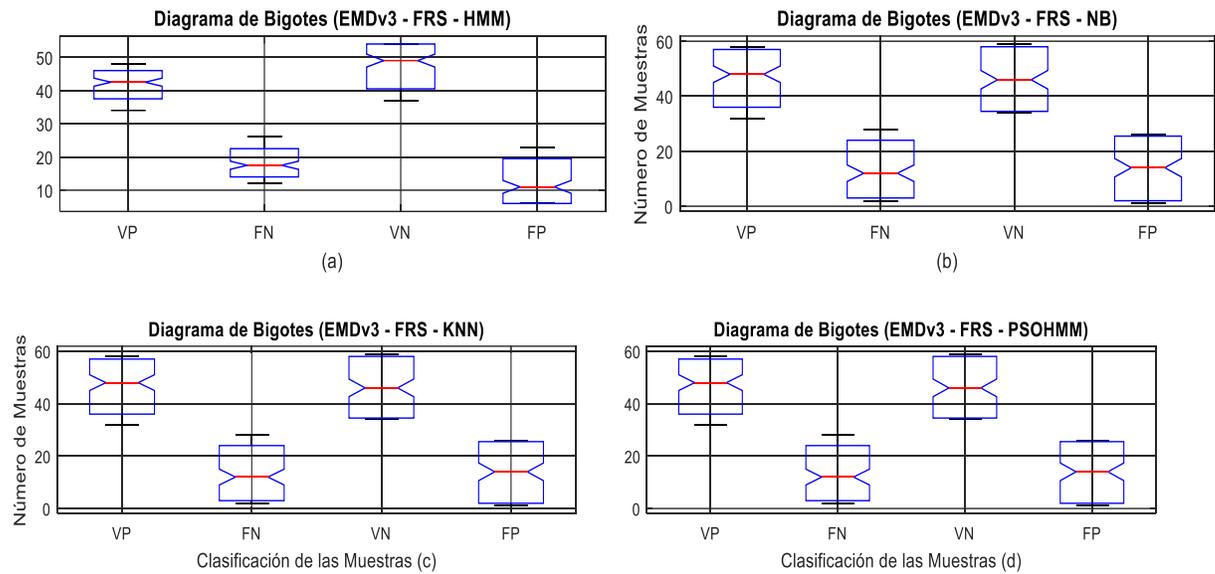


Figura B-30: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EMDv3 y el análisis de relevancia SFFS).

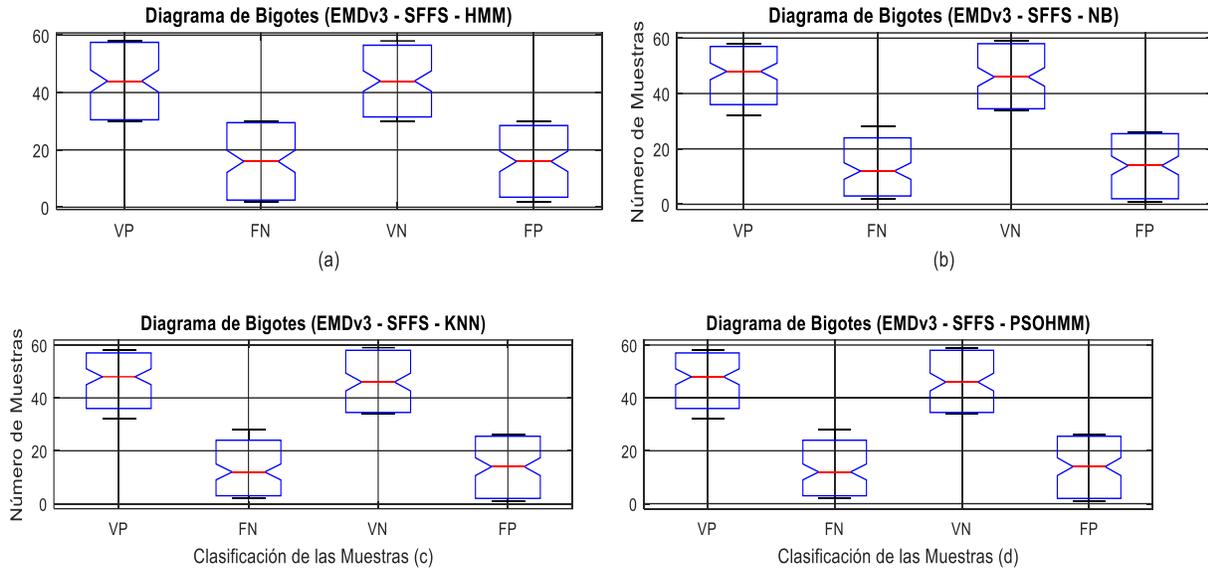


Figura B-31: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición fastEMD y el análisis de relevancia PCA).

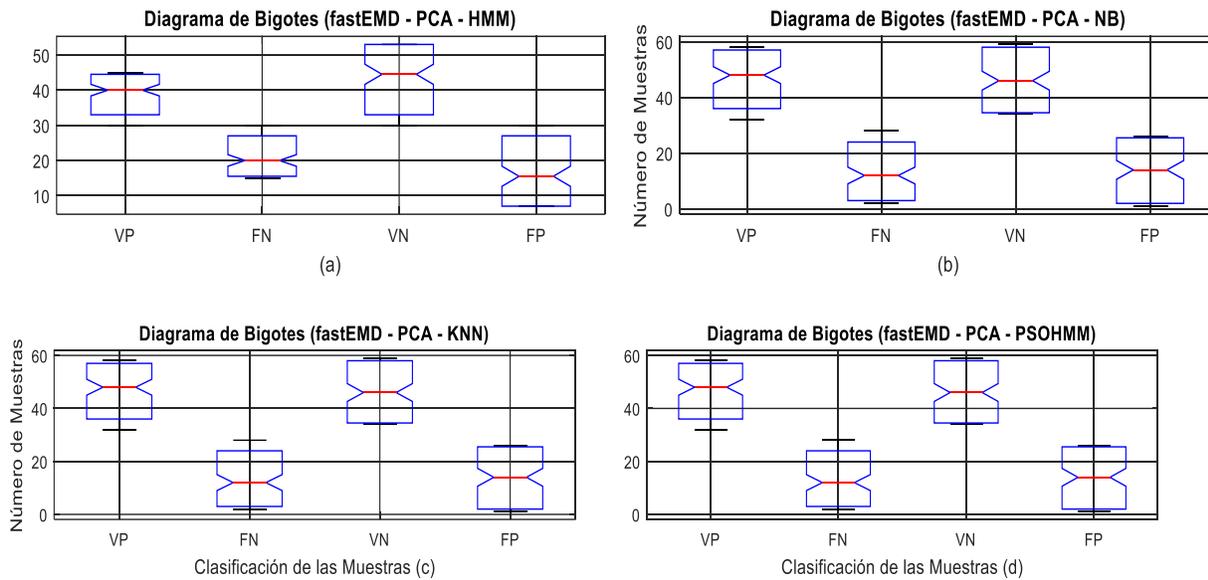


Figura B-32: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición fastEMD y el análisis de relevancia FRS).

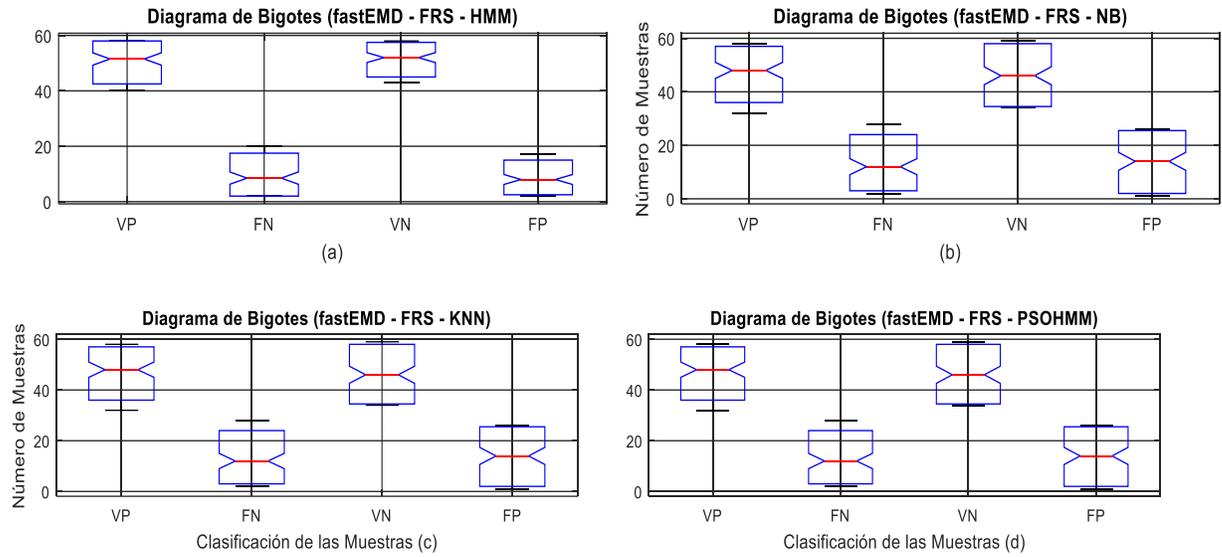


Figura B-33: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición fastEMD y el análisis de relevancia SFFS).

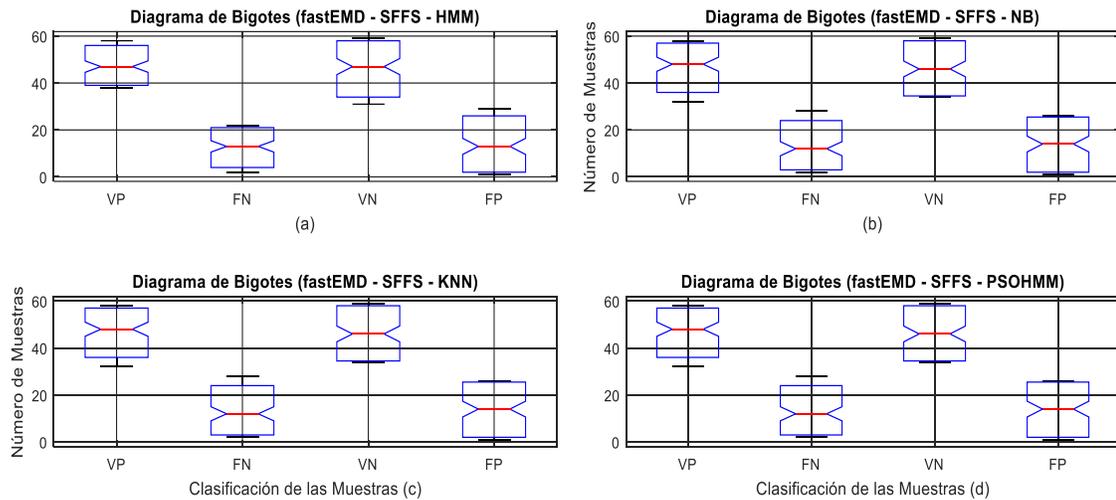


Figura B-34: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EEMDv1 y el análisis de relevancia PCA).

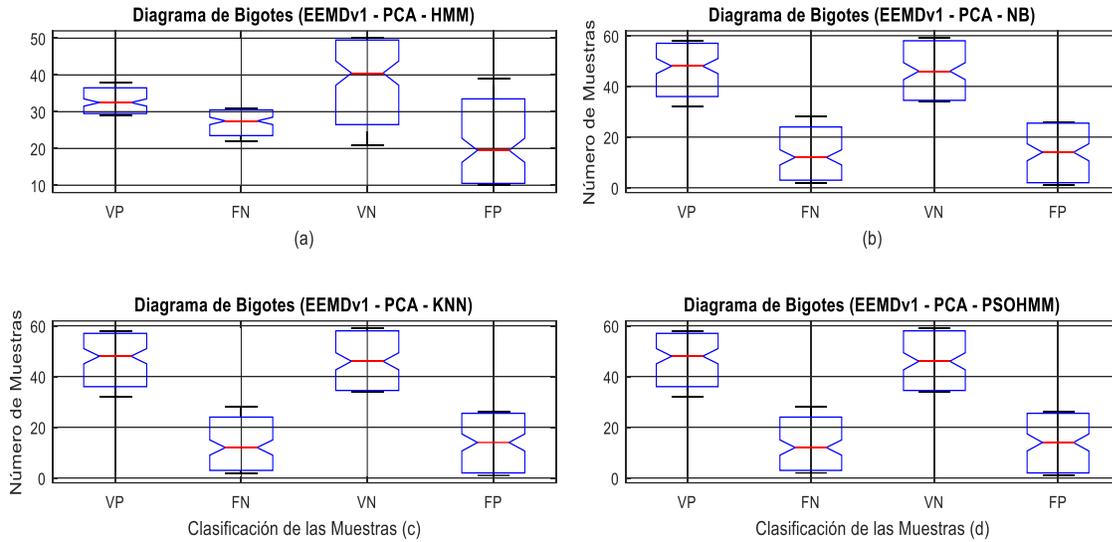


Figura B-35: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EEMDv1 y el análisis de relevancia FRS).

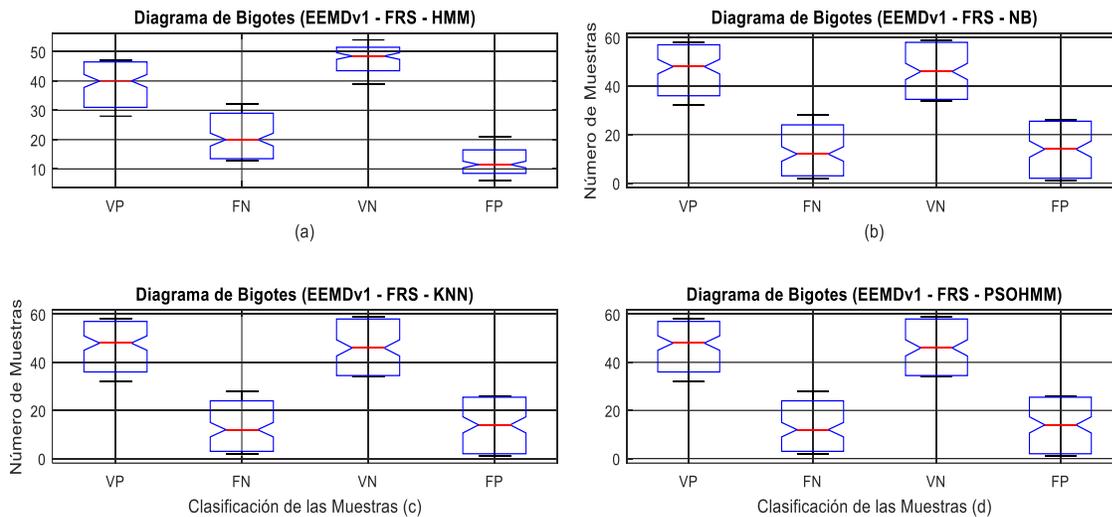


Figura B-36: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EEMDv1 y el análisis de relevancia SFFS).

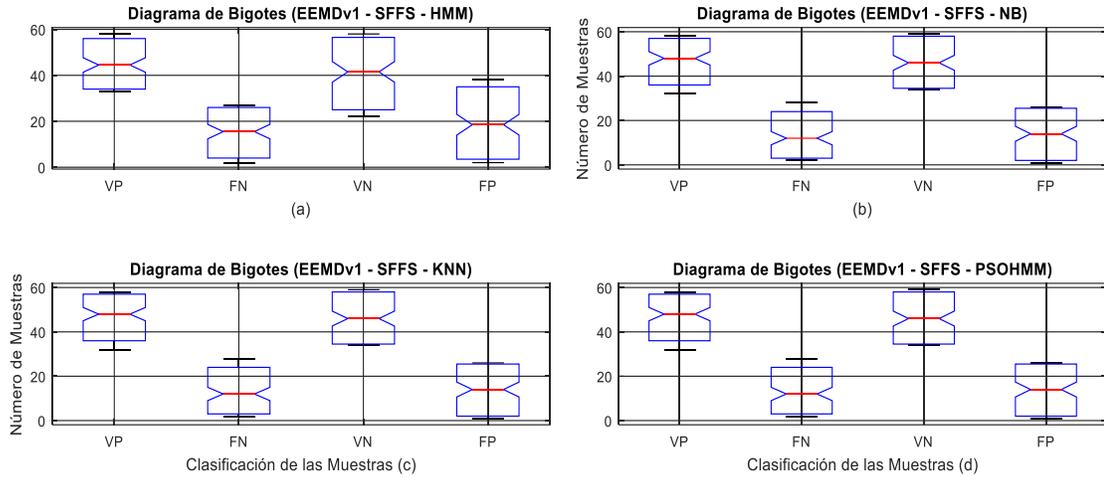


Figura B-37: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EEMDv2 y el análisis de relevancia PCA).

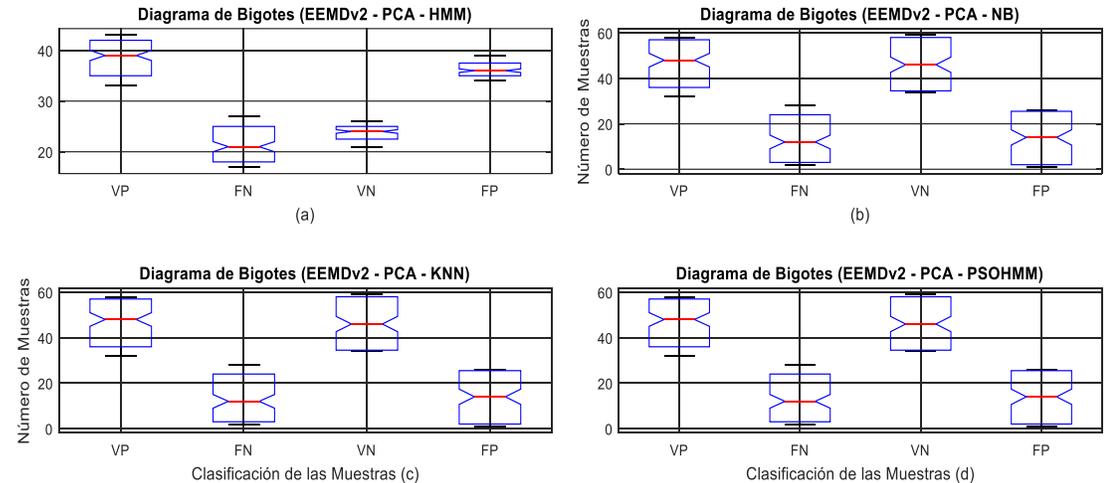


Figura B-38: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EEMDv2 y el análisis de relevancia FRS).

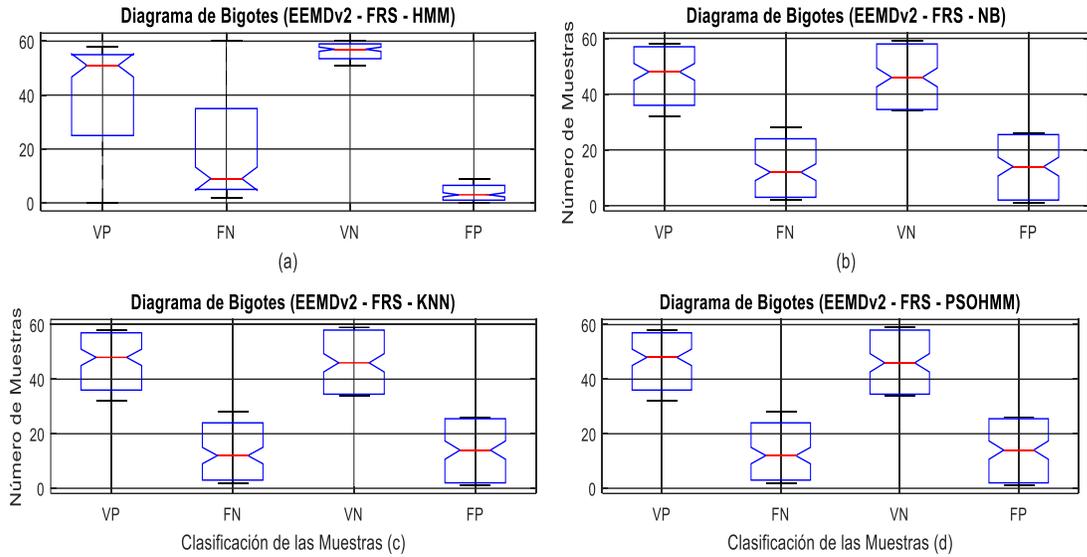


Figura B-39: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición EEMDv2 y el análisis de relevancia SFFS).

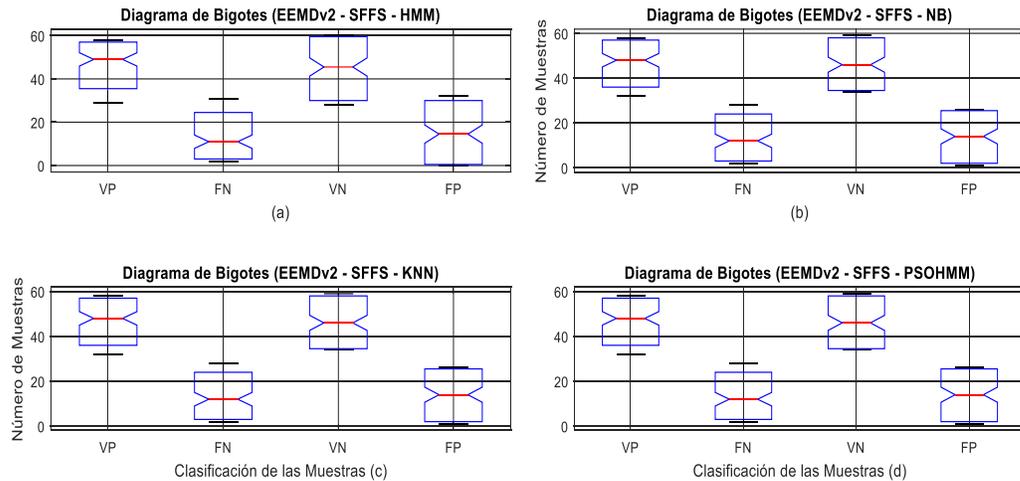


Figura B-40: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición CEEMDANv1 y el análisis de relevancia PCA).

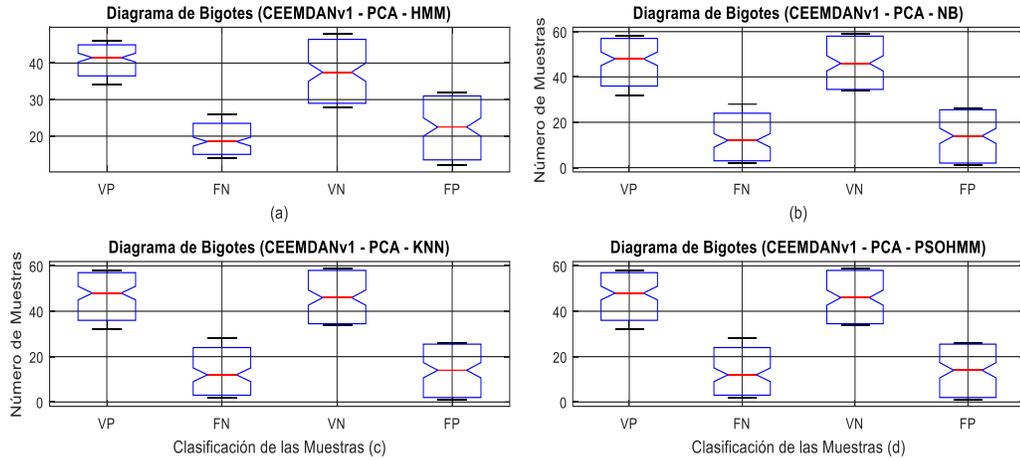


Figura B-41: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición CEEMDANv1 y el análisis de relevancia FRS).

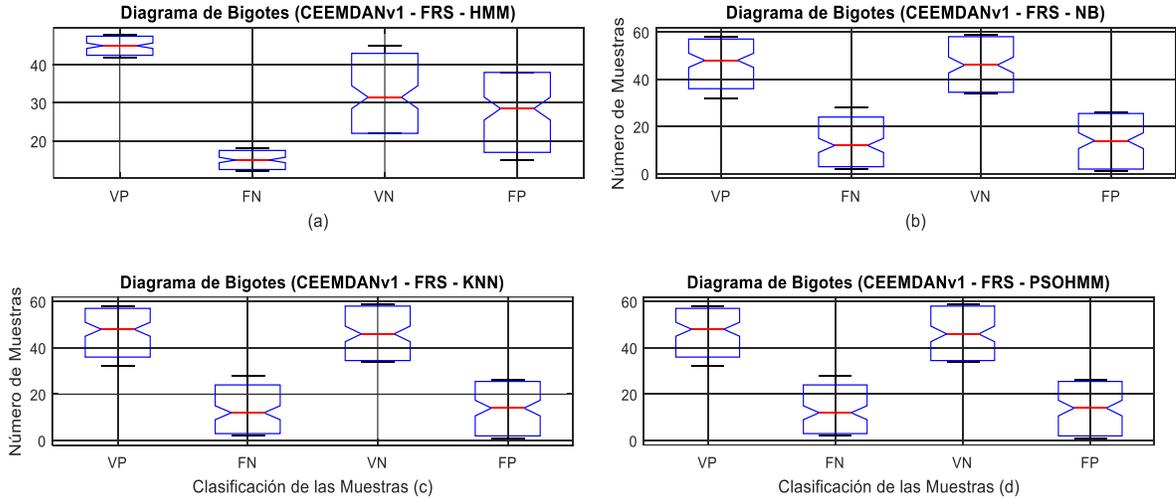


Figura B-42: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición CEEMDANv1 y el análisis de relevancia SFFS).

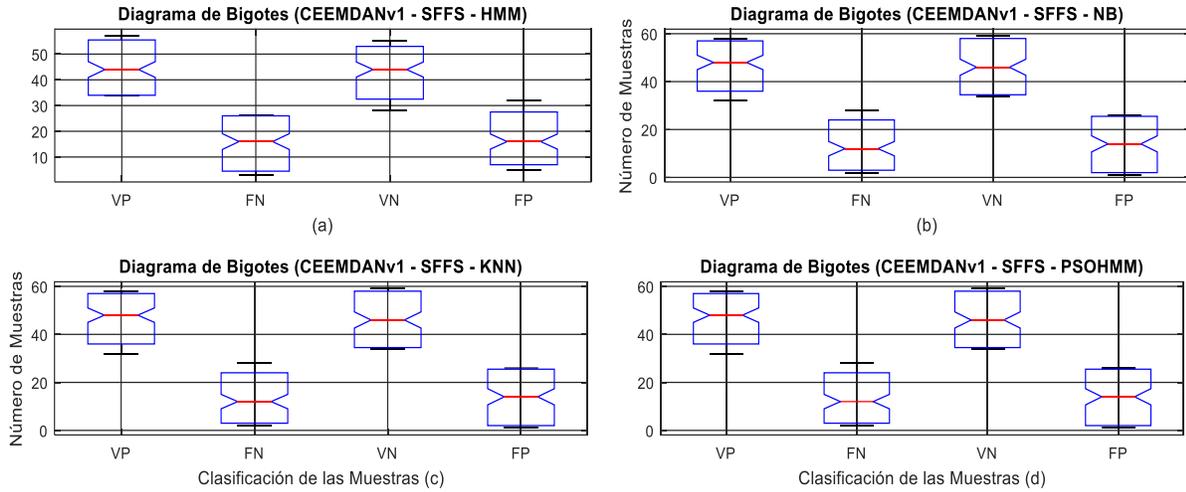


Figura B-43: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición CEEMDANv2 y el análisis de relevancia PCA).

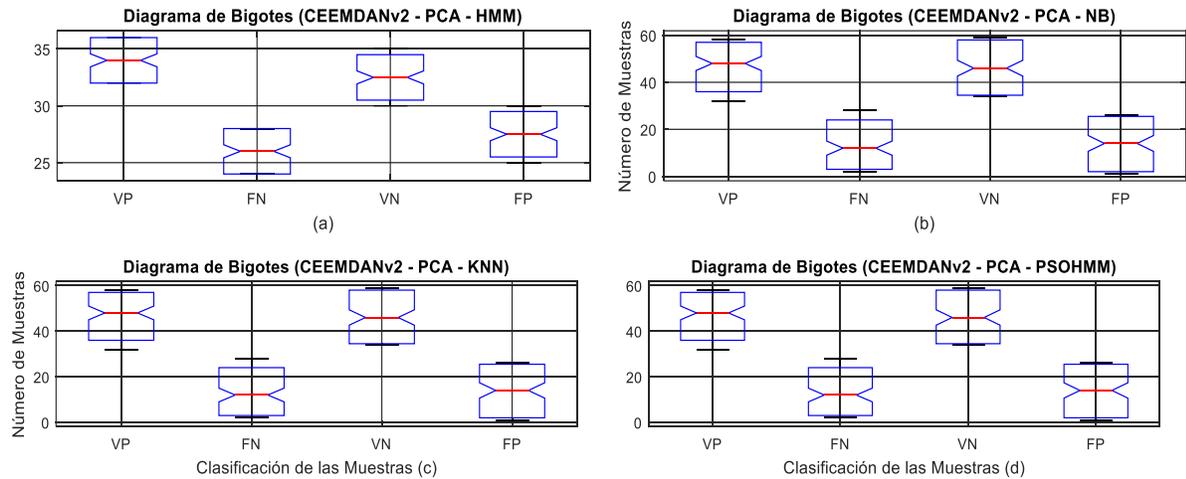


Figura B-44: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición CEEMDANv2 y el análisis de relevancia FRS).

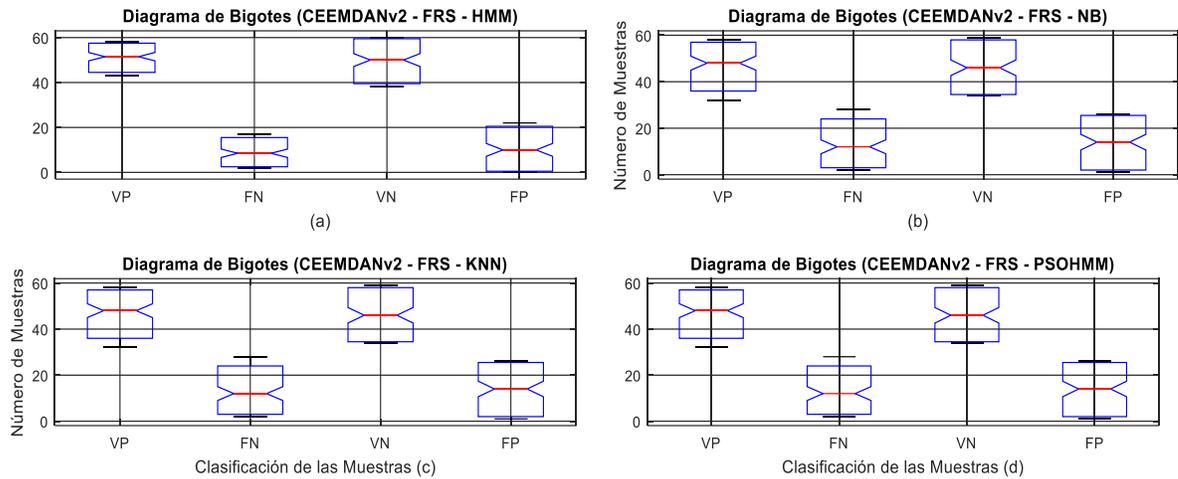
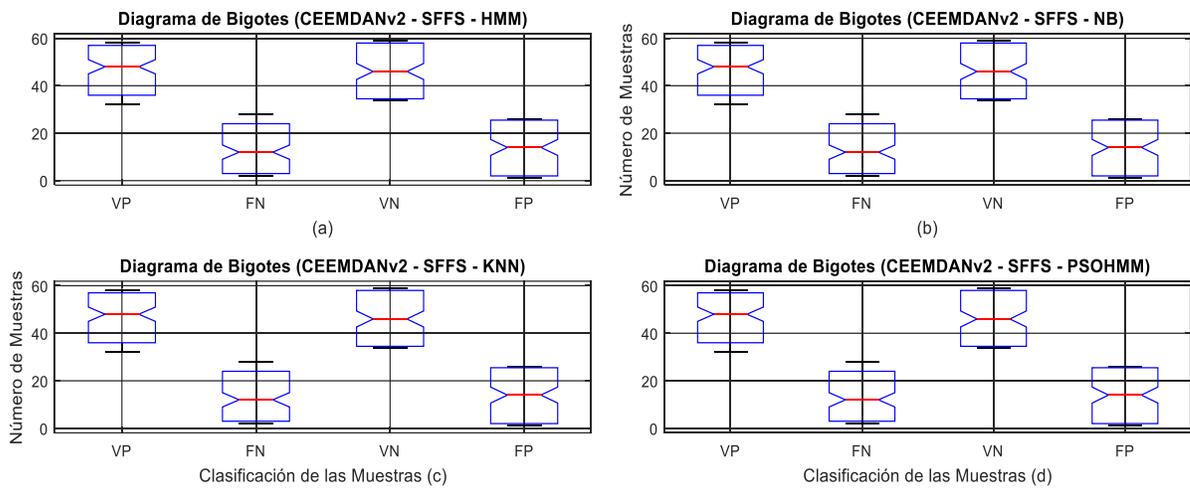


Figura B-45: Diagrama de bigotes generado a partir de los resultados obtenidos en los diferentes clasificadores (con la técnica de descomposición CEEMDANv2 y el análisis de relevancia SFFS).



A continuación (ver Tabla B-11 a la Tabla B-13) se relaciona la validación de los resultados obtenidos con los clasificadores utilizando las 13 características con más frecuencia en los análisis de relevancia realizados (ver Tabla 4-9), las cuales tienen como índices:

{[13],[14],[133],[169],[177],[179],[180],[297],[299],[305],[309],[311],[312]}

Tabla B-11: Precisión clasificadores entrenados con 13 características (normalización señal: bipolar y normalización matriz característica: unipolar)

Técnica de Descomposición	Clasificador -> Promedio \pm Desviación Estándar (Varianza)			
	HMM	Naive Bayes	KNN	PSOHMM
HVD	94.89 \pm 1.53 (0.02)	94.61 \pm 1.46 (0.02)	89.42 \pm 2.55 (0.07)	85.44 \pm 12.74 (1.62)
EMDv3	92.81 \pm 2.19 (0.05)	94.31 \pm 1.55 (0.02)	84.64 \pm 2.60 (0.07)	86.25 \pm 4.40 (0.19)
fastEMD	93.47 \pm 1.74 (0.03)	95.83 \pm 1.67 (0.03)	81.64 \pm 2.80 (0.08)	86.75 \pm 7.85 (0.62)
EEMDv2	50.00 \pm 0.00 (0.00)	98.14 \pm 1.25 (0.02)	91.58 \pm 2.07 (0.04)	93.58 \pm 2.32 (0.05)
EEMDv1	88.39 \pm 2.41 (0.06)	84.69 \pm 2.51 (0.06)	81.08 \pm 3.25 (0.11)	75.36 \pm 6.91 (0.48)
CEEMDANv1	88.58 \pm 2.54 (0.06)	89.97 \pm 2.65 (0.07)	84.69 \pm 2.77 (0.08)	81.17 \pm 8.44 (0.71)
CEEMDANv2	96.69 \pm 1.41 (0.02)	97.03 \pm 1.53 (0.02)	93.94 \pm 2.53 (0.06)	92.17 \pm 3.81 (0.14)

Tabla B-12: Valores promedio de precisión de los clasificadores entrenados con 13 características (normalización señal: unipolar y normalización matriz característica: unipolar)

Técnica de Descomposición	Clasificador -> Promedio \pm Desviación Estándar (Varianza)			
	HMM	Naive Bayes	KNN	PSOHMM
HVD	94.44 \pm 1.55 (0.02)	94.22 \pm 1.92 (0.04)	90.28 \pm 2.10 (0.04)	88.47 \pm 8.22 (0.68)
EMDv3	93.14 \pm 2.08 (0.04)	94.33 \pm 1.49 (0.02)	86.22 \pm 2.04 (0.04)	85.75 \pm 5.46 (0.30)
fastEMD	93.94 \pm 2.18 (0.05)	95.25 \pm 1.57 (0.02)	81.94 \pm 2.87 (0.08)	89.06 \pm 3.59 (0.13)
EEMDv2	97.25 \pm 1.50 (0.02)	98.00 \pm 0.99 (0.01)	91.94 \pm 2.41 (0.06)	94.56 \pm 2.39 (0.06)
EEMDv1	87.92 \pm 2.90 (0.08)	84.92 \pm 2.73 (0.07)	81.78 \pm 2.79 (0.08)	75.19 \pm 8.74 (0.76)
CEEMDANv1	88.56 \pm 2.50 (0.06)	88.89 \pm 2.14 (0.05)	85.19 \pm 2.60 (0.07)	81.94 \pm 9.15 (0.84)
CEEMDANv2	96.08 \pm 1.64 (0.03)	97.22 \pm 1.74 (0.03)	94.28 \pm 2.16 (0.05)	92.31 \pm 3.71 (0.14)

Tabla B-13: Tiempo promedio (seg) de entrenamiento de los clasificadores implementados basados en las 13 características establecidas.

Técnica de Descomposición	Clasificador -> Promedio \pm Desviación Estándar (Varianza)			
	HMM	Naive Bayes	KNN	PSOHMM
HVD	892.15 \pm 210.38 (44261.57)	0.47 \pm 0.23 (0.05)	0.02 \pm 0.01 (0.00)	16.77 \pm 16.26 (264.25)
EMDv3	916.77 \pm 181.28 (32861.50)	0.43 \pm 0.01 (0.00)	0.02 \pm 0.00 (0.00)	10.40 \pm 1.93 (3.74)
fastEMD	854.73 \pm 208.93 (43651.65)	0.43 \pm 0.01 (0.00)	0.02 \pm 0.00 (0.00)	12.40 \pm 11.45 (131.10)
EEMDv2	492.53 \pm 123.69 (15299.70)	0.43 \pm 0.01 (0.00)	0.02 \pm 0.00 (0.00)	10.91 \pm 1.93 (3.71)
EEMDv1	587.73 \pm 166.05 (27571.74)	0.43 \pm 0.01 (0.00)	0.02 \pm 0.00 (0.00)	11.42 \pm 11.71 (137.06)
CEEMDANv1	635.08 \pm 139.24 (19387.49)	0.43 \pm 0.01 (0.00)	0.02 \pm 0.00 (0.00)	12.23 \pm 10.28 (105.77)
CEEMDANv2	1011.48 \pm 224.71 (50492.87)	0.43 \pm 0.01 (0.00)	0.02 \pm 0.00 (0.00)	10.38 \pm 1.79 (3.22)

En la Figura B-46 a la Figura B-51 el análisis está basado en una matriz con 13 características con pre-normalización bipolar y post-normalización unipolar, mientras que en las figuras Figura B-52 a Figura B-53 se parte de una matriz de características con pre-normalización unipolar y post-normalización unipolar. Se aprecian la precisión (ACC) y el área bajo la curva (AUC) como el promedio de la validación de 60 señales PCG, a partir de dos redes HMM (red Normal y Sopro) entrenadas con 140 señales a partir de una.

Figura B-46: Curva ROC clasificador HMM con 13 características (normalización señal: bipolar y normalización matriz característica: unipolar).

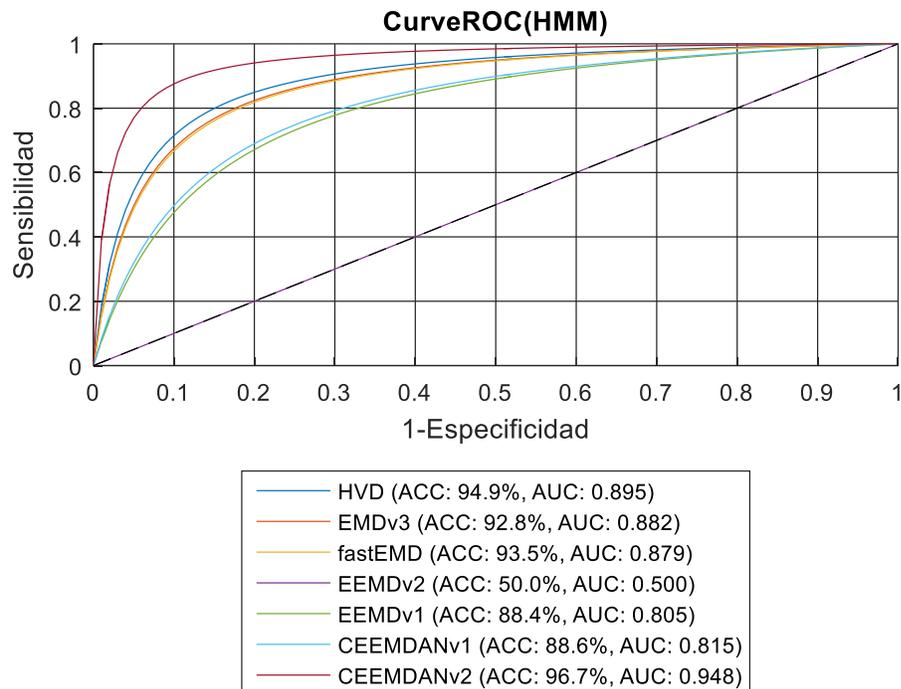


Figura B-47: Curva ROC clasificador PSOHMM con 13 características (normalización señal: bipolar y normalización matriz característica: unipolar).

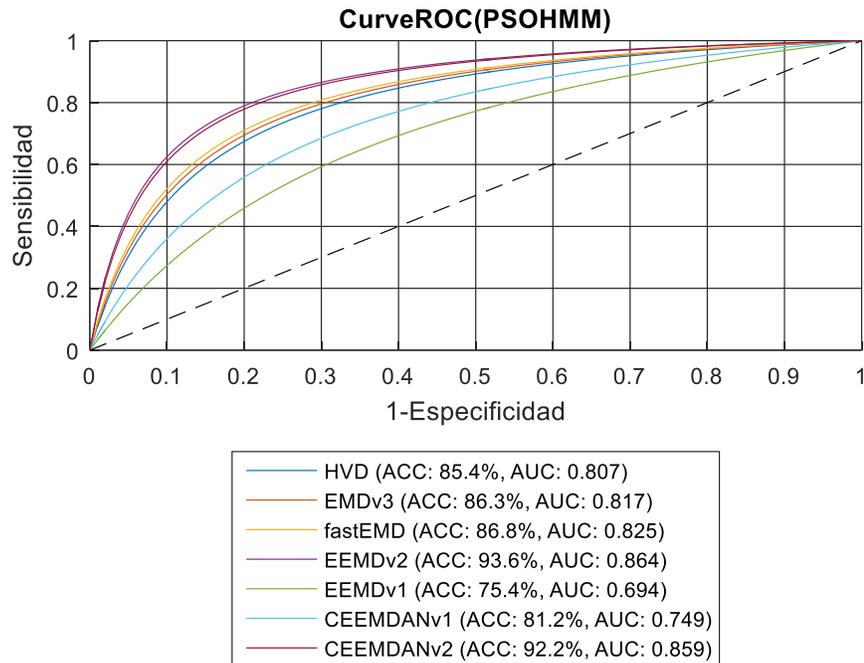


Figura B-48: Curva ROC clasificador HMM con 13 características (normalización señal: unipolar y normalización matriz característica: unipolar).

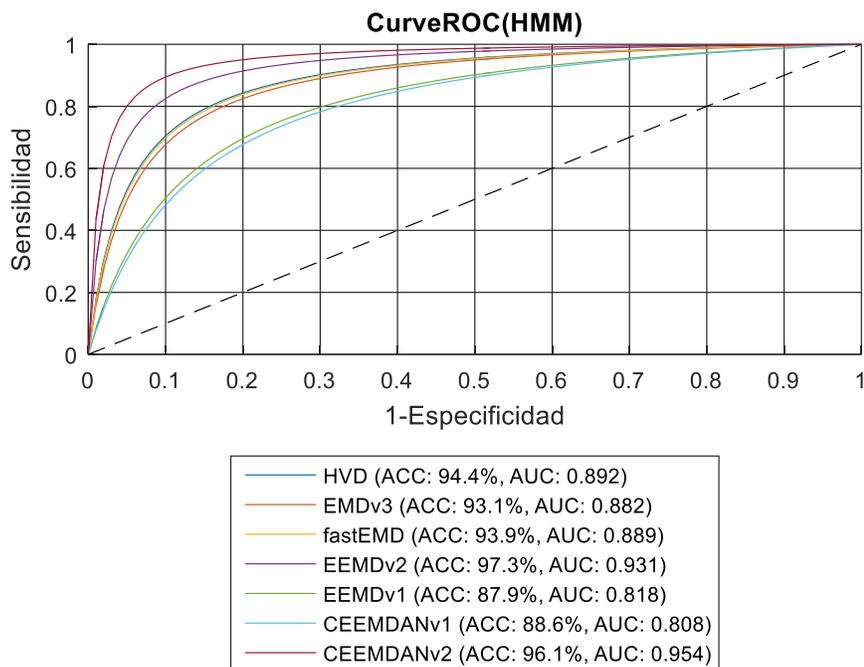


Figura B-49: Curva ROC clasificador PSOHMM con 13 características (normalización señal: unipolar y normalización matriz característica: unipolar).

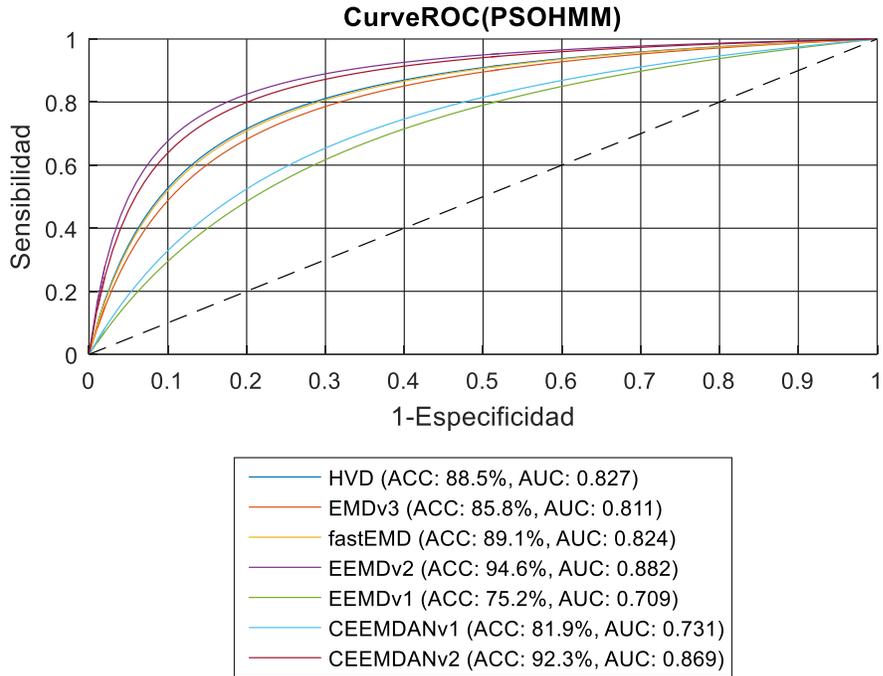


Figura B-50: Diagramas de bigotes clasificador HMM (normalización señal: bipolar y normalización matriz característica: unipolar).

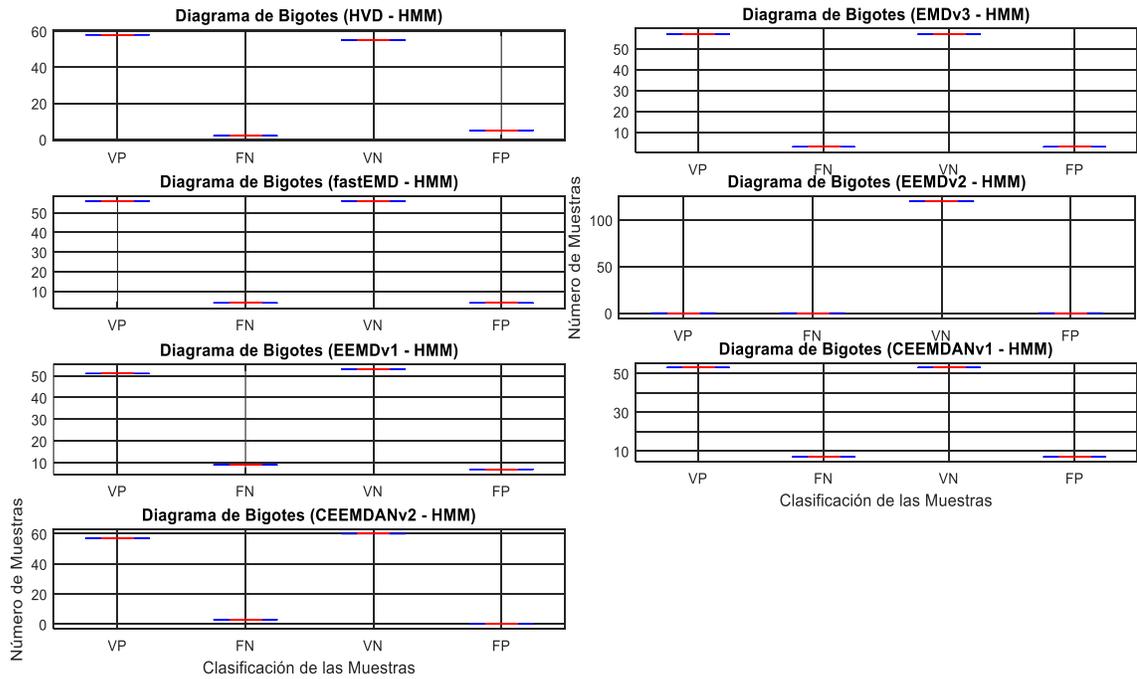


Figura B-51: Diagramas de bigotes clasificador PSOHMM (normalización señal: bipolar y normalización matriz característica: unipolar).

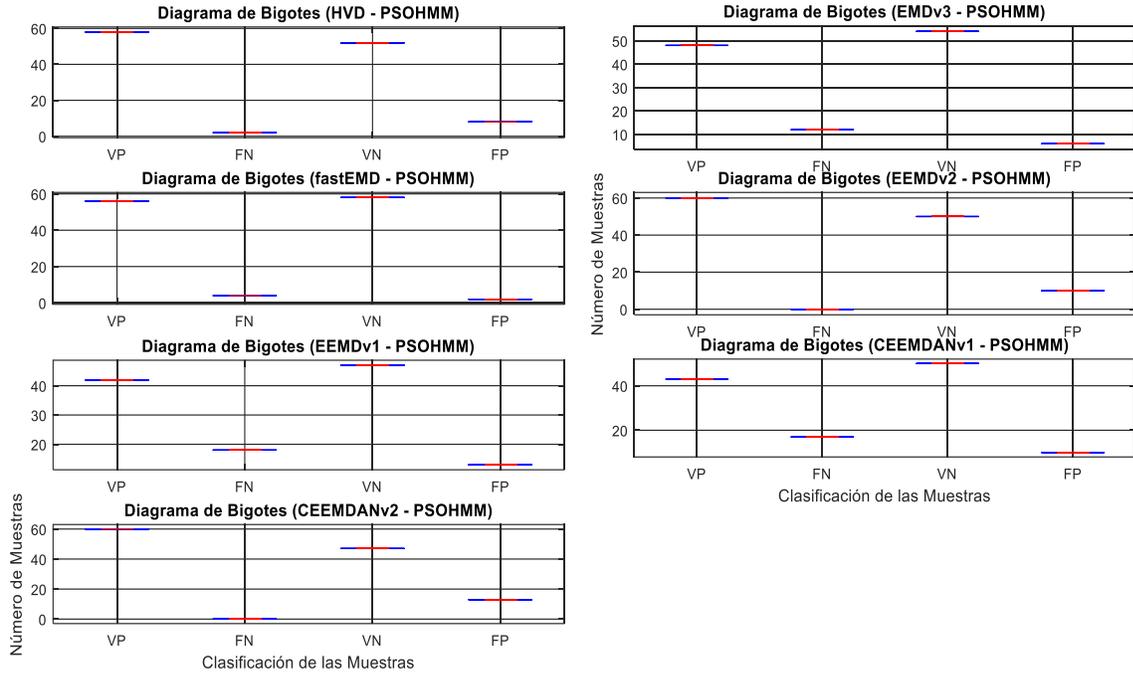


Figura B-52: Diagramas de bigotes clasificador HMM (normalización señal: unipolar y normalización matriz característica: unipolar).

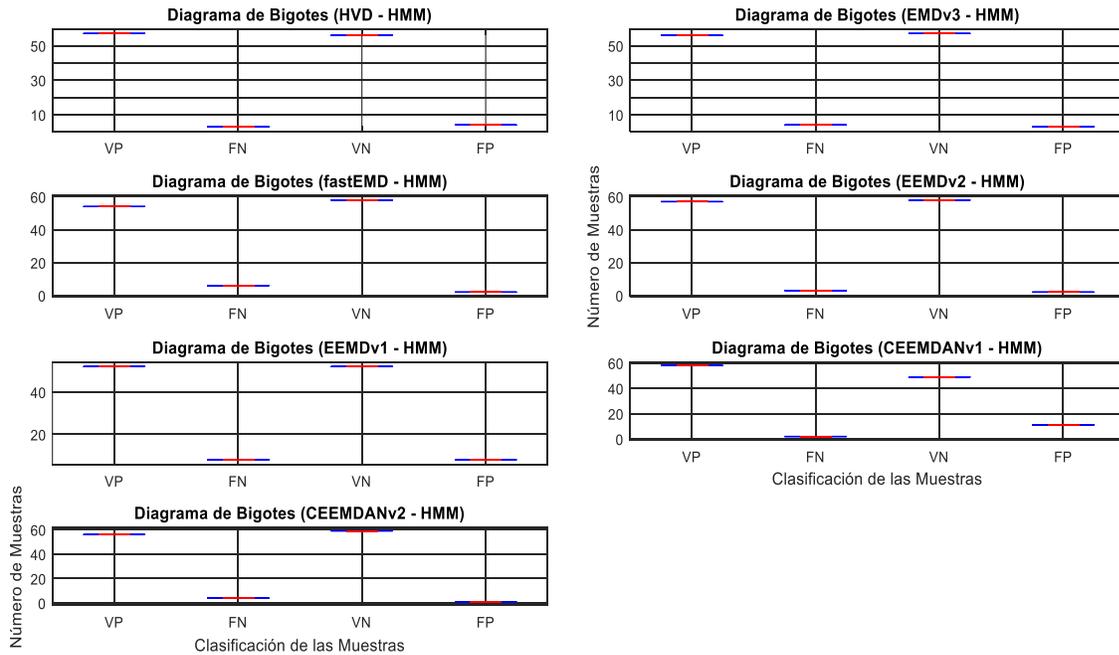
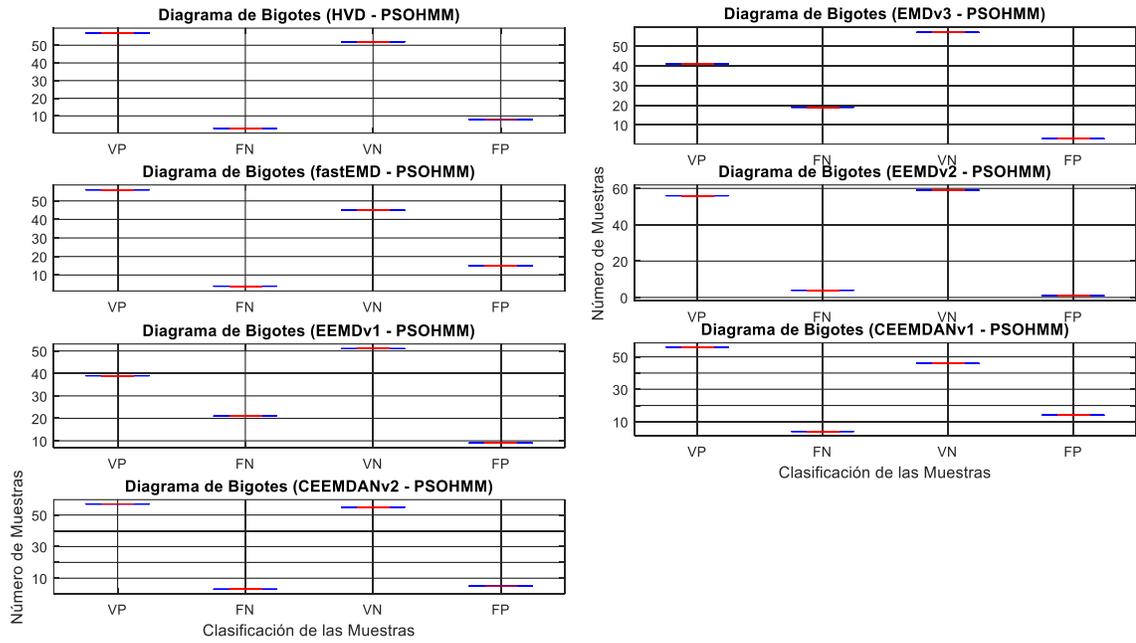


Figura B-53: Diagramas de bigotes clasificador PSOHMM (normalización señal: unipolar y normalización matriz característica: unipolar).



Referencias

- Abo-Zahhad, M., Farrag, M., Abbas, S. N., & Ahmed, S. M. (2016). A comparative approach between cepstral features for human authentication using heart sounds. *Signal, Image and Video Processing*, 10(5), 843–851. doi:10.1007/s11760-015-0826-9
- Aggarwal, R. K., & Dave, M. (2012). Filterbank optimization for robust ASR using GA and PSO. *International Journal of Speech Technology*, 15(2), 191–201. doi:10.1007/s10772-012-9133-9
- Ahlstrom, C., Hult, P., Rask, P., Karlsson, J.-E., Nylander, E., Dahlström, U., & Ask, P. (2006). Feature Extraction for Systolic Heart Murmur Classification. *Annals of Biomedical Engineering*, 34(11), 1666–1677. doi:10.1007/s10439-006-9187-4
- Ahrabian, A., Rehman, N. U., & Mandic, D. (2013). Bivariate Empirical Mode Decomposition for Unbalanced Real-World Signals. *IEEE Signal Processing Letters*, 20(3), 245–248. doi:10.1109/LSP.2013.2242062
- Akay, M. (1992). Noninvasive diagnosis of coronary artery disease using a neural network algorithm. *Biological Cybernetics*, 67(4), 361–367. doi:10.1007/BF02414891
- Akhter, N., Tharewal, S., Kale, V., Bhalerao, A., & Kale, K. V. (2016). Heart-Based Biometrics and Possible Use of Heart Rate Variability in Biometric Recognition Systems BT - Advanced Computing and Systems for Security: Volume 1. In R. Chaki, A. Cortesi, K. Saeed, & N. Chaki (Eds.), (pp. 15–29). New Delhi: Springer India. doi:10.1007/978-81-322-2650-5_2
- Alfi, A. (2011). PSO with Adaptive Mutation and Inertia Weight and Its Application in Parameter Estimation of Dynamic Systems. *Acta Automatica Sinica*, 37(5), 541–549. doi:10.1016/S1874-1029(11)60205-X
- Amoud, H., Snoussi, H., Hewson, D., & Duchêne, J. (2008). Univariate and Bivariate Empirical Mode Decomposition for Postural Stability Analysis. *EURASIP Journal on Advances in Signal Processing*, 2008(1), 1–11. doi:10.1155/2008/657391
- Andrés, C., Delgado, E., Godino, J., & Castellanos, G. (2007). Acoustic Analysis Oriented to the Cardiac Murmur Detection over Digital Auscultation Signals. *Revista Avances En Sistemas E Informática*, 4(3), 171–182.

- Aote, S., Raghuwanshi, M., & Malik, L. (2013). A Brief Review on Particle Swarm Optimization : Limitations & Future Directions. *Citeseer*, 2(05), 196–200.
- Aupetit, S., Monmarché, N., & Slimane, M. (2007). Hidden Markov Models Training by a Particle Swarm Optimization Algorithm. *Journal of Mathematical Modelling and Algorithms*, 6(2), 175–193. doi:10.1007/s10852-005-9037-7
- Babaei, S., & Geranmayeh, A. (2009). Heart sound reproduction based on neural network classification of cardiac valve disorders using wavelet transforms of PCG signals. *Computers in Biology and Medicine*, 39(1), 8–15. doi:http://dx.doi.org/10.1016/j.combiomed.2008.10.004
- Barma, S., Chen, B.-W., Wang, H.-M., Wang, H.-J., & Wang, J.-F. (2015). Second Heart Sound (S2) Decomposition by Hilbert Vibration Decomposition (HVD) for Affective Signal Modeling and Learning BT - Advances in Web-Based Learning – ICWL 2013 Workshops: USL 2013, IWSLL 2013, KMEL 2013, IWCWL 2013, WIL 2013, and IWEEC 2013, Ken. In W. D. K. Chiu, M. Wang, E. Popescu, Q. Li, R. Lau, K. T. Shih, ... G. D. Sampson (Eds.), (pp. 223–233). Berlin, Heidelberg: Springer Berlin Heidelberg. doi:10.1007/978-3-662-46315-4_23
- Barry, D. T., & Cole, N. M. (1990). Muscle sounds are emitted at the resonant frequencies of skeletal muscle. *IEEE Transactions on Biomedical Engineering*, 37(5), 525–531. doi:10.1109/10.55644
- Becerra Botero, M. A. (2013). *Metodología Dinámica Sobre Espacios de Representación Abstracta Basada en Técnicas Estocásticas Orientada a la Detección de Soplos Cardíacos a Partir de los Cuatro Focos de Auscultación*. Instituto Tecnológico Metropolitano.
- Becerra, M. A., Orrego, D. A., Mejia, C., & Delgado Trejos, E. (2012). Stochastic Analysis and Classification of 4-Area Cardiac Auscultation Signals using Empirical Mode Decomposition and Acoustic Features. *Computing in Cardiology*, 39, 529–532.
- Bensch, M., Schröder, M., Bogdan, M., & Rosenstiel, W. (2005). Feature selection for high-dimensional industrial data. In *ESANN* (pp. 375–380).
- Beritelli, F., & Spadaccini, A. (2011). Human identity verification based on heart sounds: recent advances and future directions. *arXiv Preprint arXiv:1105.4058*.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Secaucus, NJ, USA: Springer-Verlag New York, Inc.

- Blakely, C. D. (2005). A Fast Empirical Mode Decomposition Technique for Nonstationary Nonlinear Time Series. *October*, (October 2005), 14.
- Botha, J. S. F., Scheffer, C., Lubbe, W. W., & Doubell, A. F. (2010). Autonomous auscultation of the human heart employing a precordial electro-phonocardiogram and ensemble empirical mode decomposition. *Australasian Physical & Engineering Sciences in Medicine*, 33(2), 171–183. doi:10.1007/s13246-010-0021-9
- Castiglioni, P. (2005). Choi–Williams Distribution. In *Encyclopedia of Biostatistics*. John Wiley & Sons, Ltd. doi:10.1002/0470011815.b2a12012
- Cerda, J., & Cifuentes, L. (2012). Uso de curvas ROC en investigación clínica: Aspectos teórico-prácticos. *Revista Chilena de Infectología*, 29(2), 138–141. doi:10.4067/S0716-10182012000200003
- Chan, H.-L., Huang, H.-H., & Lin, J.-L. (2001). Time-Frequency Analysis of Heart Rate Variability During Transient Segments. *Annals of Biomedical Engineering*, 29(11), 983–996. doi:10.1114/1.1415525
- Chauhan, S., Wang, P., Sing Lim, C., & Anantharaman, V. (2008). A computer-aided MFCC-based HMM system for automatic auscultation. *Computers in Biology and Medicine*, 38(2), 221–233. doi:10.1016/j.compbiomed.2007.10.006
- Chernick, M. R., Murthy, V. K., & Nealy, C. D. (1985). Application of bootstrap and other resampling techniques: Evaluation of classifier performance. *Pattern Recognition Letters*, 3(3), 167–178. doi:http://dx.doi.org/10.1016/0167-8655(85)90049-2
- Cohen, L. (1995). *Time-frequency analysis* (Vol. 778). Prentice hall.
- Colominas, M. a., Schlotthauer, G., Torres, M. E., & Flandrin, P. (2012). Noise-Assisted Emd Methods in Action. *Advances in Adaptive Data Analysis*, 04(04), 1250025. doi:10.1142/S1793536912500252
- Confrence, I., & Sian, C. (2010). Signal Denoising Based on EEMD for Non-stationary Signals and Its Application, 2(1), 334–338.
- Dash, M., & Liu, H. (1997). Feature selection for classification. *Intelligent Data Analysis*, 1(3), 131–156.
- Dave, N. (2013). Feature Extraction Methods LPC, PLP and MFCC In Speech Recognition. *International Journal For Advance Research in Engineering And Technology*, ISSN 2320-6802, 1(VI), 1–5.

- Debbal, S. M., & Bereksi-Reguig, F. (2008). Computerized heart sounds analysis. *Computers in Biology and Medicine*, 38(2), 263–280. doi:<http://dx.doi.org/10.1016/j.compbiomed.2007.09.006>
- Deisy, C., Subbulakshmi, B., Baskar, S., & Ramaraj, N. (2007). Efficient Dimensionality Reduction Approaches for Feature Selection. *International Conference on Conference on Computational Intelligence and Multimedia Applications*, 2, 121–127.
- Delgado, E. (2008). *Generación y Extracción/Selección de Características en la Detección Automática de Isquemia y Deficiencias Valvulares sobre Registros de la Actividad Cardíaca*. Universidad Nacional de Colombia.
- Delgado, E., Quiceno-Manrique, A. F., Godino-Llorente, J. I., Blanco-Velasco, M., & Castellanos-Dominguez, G. (2009). Digital Auscultation Analysis for Heart Murmur Detection. *Annals of Biomedical Engineering*, 37(2), 337–353. doi:10.1007/s10439-008-9611-z
- El-Bendary, N., Al-Qaheri, H., Zawbaa, H. M., Hamed, M., Hassanien, A. E., Zhao, Q., & Abraham, A. (2010). HSAS: Heart Sound Authentication System. In *Nature and Biologically Inspired Computing (NaBIC), 2010 Second World Congress on* (pp. 351–356). doi:10.1109/NABIC.2010.5716306
- Ergen, B., Tatar, Y., & Gulcur, H. O. (2010). Time – frequency analysis of phonocardiogram signals using wavelet transform : a comparative study. *Computer Methods in Biomechanics and Biomedical Engineering*, 15, 371–381.
- Ewing, G. J. (1988). *A New Approach to the Analysis of the third Heart Sound*. University of Adelaide.
- Feldman, M. (2008). Theoretical analysis and comparison of the Hilbert transform decomposition methods. *Mechanical Systems and Signal Processing*, 22(3), 509–519.
- Feldman, M. (2011). Hilbert transform in vibration analysis. *Mechanical Systems and Signal Processing*, 25(3), 735–802. doi:<http://dx.doi.org/10.1016/j.ymsp.2010.07.018>
- Freitas, C., Carvalho, J., Oliveira, J., Aires, S., & Sabourin, R. (2007). Confusion matrix disagreement for multiple classifiers. *Progress in Pattern ...*, 387–396.
- Ganong, W. (2010). *Fisiología médica*. (S. M. Barman, S. Boitano, & H. Brooks, Eds.) (23rd ed.). McGraw-Hill.
- Gautam, G. (2013). *Biometric identification using analysis of cardiac sound*.

- Gersho, A., & Gray, R. M. (1991). *Vector Quantization and Signal Compression*. Norwell, MA, USA: Kluwer Academic Publishers.
- Gheyas, I. A., & Smith, L. S. (2010). Feature subset selection in large dimensionality domains. *Pattern Recognition*, 43(1), 5–13. doi:http://dx.doi.org/10.1016/j.patcog.2009.06.009
- Giraldo, L. F., Delgado, E., & Castellanos, C. G. (2007). Feature weighting and selection using a hybrid approach based on Rademacher complexity model selection. In *2007 Computers in Cardiology* (pp. 257–260). doi:10.1109/CIC.2007.4745470
- Gupta, C. N., Palaniappan, R., Swaminathan, S., & Krishnan, S. M. (2007). Neural Network Classification of Homomorphic Segmented Heart Sounds. *Appl. Soft Comput.*, 7(1), 286–297. doi:10.1016/j.asoc.2005.06.006
- Hariharan, M., Polat, K., & Sindhu, R. (2014). A new hybrid intelligent system for accurate detection of Parkinson's disease. *Computer Methods and Programs in Biomedicine*, 113(3), 904–913.
- Homaeinezhad, M. R., Tavakkoli, E., Habibi, M., Atyabi, S. A., & Ghaffari, A. (2011). Combination of different classifiers for cardiac arrhythmia recognition. *World Academy of Science, Engineering and Technology*, 1189–1200.
- Hönig, F., Stemmer, G., Hacker, C., & Brugnera, F. (2005). Revising Perceptual Linear Prediction (PLP). In *INTERSPEECH* (pp. 2997–3000).
- Huan, Y., Liu, Y., & Hong, Z. (2009). Detection and Location of Power Quality Disturbances Based on Mathematical Morphology and Hilbert-Huang Transform. *The Ninth International Conference on Electronic Measurement & Instruments*, 319–324.
- Huang, B., & Kunoth, A. (2013). An Optimization Based Empirical Mode Decomposition Scheme, (October 2012).
- Huang, J.-R., Fan, S.-Z., Abbod, M., Jen, K.-K., Wu, J.-F., & Shieh, J.-S. (2013). Application of Multivariate Empirical Mode Decomposition and Sample Entropy in EEG Signals via Artificial Neural Networks for Interpreting Depth of Anesthesia. *Entropy*, 15(9), 3325–3339. doi:10.3390/e15093325
- Huang, N. E. (2005). Introduction to the Hilbert–Huang Transform and Its Related Mathematical Problems. In *Hilbert-Huang Transform and Its Applications* (Vol. Volume 5, pp. 1–26). WORLD SCIENTIFIC. doi:10.1142/9789812703347_0001
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q. Liu, H. H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-

- stationary time series analysis. In *Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences* (Vol. 454, pp. 903–995).
- Huang, S., Yang, D., Yongxin, G., & Zhang, X. (2015). Combined supervised information with PCA via discriminative component selection. *Information Processing Letters*, 115(11), 812–816. doi:<http://dx.doi.org/10.1016/j.ipl.2015.06.010>
- Humeau-Heurtier, A., Abraham, P., & Mahe, G. (2014). Analysis of laser speckle contrast images variability using a novel empirical mode decomposition: comparison of results with laser Doppler flowmetry signals variability. *IEEE Transactions on Medical Imaging*, 0062(c), 1–10. doi:10.1109/TMI.2014.2364079
- Ibe, O. C. (2014). Chapter 8 - Introduction to Descriptive Statistics. In O. C. B. T.-F. of A. P. and R. P. (Second E. Ibe (Ed.), (pp. 253–274). Boston: Academic Press. doi:<http://dx.doi.org/10.1016/B978-0-12-800852-2.00008-0>
- Jensen, R., & Shen, Q. (2008). *Computational Intelligence and Feature Selection: Rough and Fuzzy Approaches*. Wiley-IEEE Press. doi:10.1002/9780470377888
- Kalantari, M., Yarmohammadi, M., & Hassani, H. (2016). Singular Spectrum Analysis Based on L 1-Norm. *Fluctuation and Noise Letters*, 1650009.
- Kamarulafizam, I., Salleh, S., Najeb, J. M., Ariff, A. K., & Chowdhury, A. (2007a). Heart Sound Analysis Using MFCC and Time Frequency Distribution. *Center for Biomedical Engineering*, 15(2), 402–405.
- Kamarulafizam, I., Salleh, S.-H., Najeb, J. M., Ariff, A. K., & Chowdhury, A. (2007b). Heart Sound Analysis Using MFCC and Time Frequency Distribution BT - World Congress on Medical Physics and Biomedical Engineering 2006: August 27 – September 1, 2006 COEX Seoul, Korea “Imaging the Future Medicine.” In R. Magjarevic & J. H. Nagel (Eds.), (pp. 946–949). Berlin, Heidelberg: Springer Berlin Heidelberg. doi:10.1007/978-3-540-36841-0_225
- Kaslovsky, D., & Meyer, F. (2010). Noise Corruption of Empirical Mode Decomposition and its Effect on Instantaneous Frequency. *Advances in Adaptive Data Analysis*, 02(03), 373–396. doi:10.1142/S1793536910000537
- Kay, S. M., & Marple Jr., S. L. (1981). Spectrum Analysis -- A Modern Perspective. *Proceedings of IEEE*, 69(11), 1380–1418.

- Kopsinis, Y., & McLaughlin, S. (2009). Development of EMD-Based Denoising Methods Inspired by Wavelet Thresholding. *IEEE Transactions on Signal Processing*, 57(4), 1351–1362. doi:10.1109/TSP.2009.2013885
- Kostantinos, N. (2000). Gaussian mixtures and their applications to signal processing. *Advanced Signal Processing Handbook: Theory and Implementation for Radar, Sonar, and Medical Imaging Real Time Systems*, 1–3.
- Leung, T. S., White, P. R., Collis, W. B., Brown, E., & Salmon, A. P. (2000). Classification of heart sounds using time-frequency method and artificial neural networks. In *Engineering in Medicine and Biology Society, 2000. Proceedings of the 22nd Annual International Conference of the IEEE* (Vol. 2, pp. 988–991 vol.2). doi:10.1109/IEMBS.2000.897889
- Li, X., Li, X., Zheng, X., & Zhang, D. (2010). EMD-TEO Based Speech Emotion Recognition. In K. Li, M. Fei, L. Jia, & G. Irwin (Eds.), *Life System Modeling and Intelligent Computing SE - 20* (Vol. 6329, pp. 180–189). Springer Berlin Heidelberg. doi:10.1007/978-3-642-15597-0_20
- Li, X., Liu, M., & Wang, S. (2010). Research on the EEMD algorithm of penetration acceleration signal processing based on independent component analysis. *2010 3rd International Congress on Image and Signal Processing*, 4135–4138. doi:10.1109/CISP.2010.5646195
- Lin, W., Zhang, Y., Jia, Z., Chen, H., Zhang, K., & Li, Z. (2013). Delicate separation of Doppler blood flow and vessel wall beat signals by using the EEMD-based algorithm. *2013 6th International Conference on Biomedical Engineering and Informatics, (Bmei)*, 224–228. doi:10.1109/BMEI.2013.6746938
- Liu, C., Liu, C., Li, L., Zhang, Q., & Li, B. (2009). Systolic and Diastolic Time Interval Variability Analysis and Their Relations with Heart Rate Variability. In *2009 3rd International Conference on Bioinformatics and Biomedical Engineering* (pp. 1–4). doi:10.1109/ICBBE.2009.5163559
- Looney, D., & Mandie, D. P. (2009). Multiscale Image Fusion Using Complex Extensions of EMD. *Trans. Sig. Proc.*, 57(4), 1626–1630. doi:10.1109/TSP.2008.2011836
- Loong, J. L. C., Subari, K. S., Abdullah, M. K., Ahmad, N. N., & Others. (2010). Comparison of MFCC and cepstral coefficients as a feature set for PCG biometric systems. *World Academy of Science, Engineering and Technology, International Journal of Medical, Health, Biomedical, Bioengineering and Pharmaceutical Engineering*, 4(8), 335–339.

-
- Luengo, J., & Herrera, F. (2012). Shared domains of competence of approximate learning models using measures of separability of classes. *Information Sciences*, *185*(1), 43–65. doi:<http://dx.doi.org/10.1016/j.ins.2011.09.022>
- Mandic, D. P., u. Rehman, N., Wu, Z., & Huang, N. E. (2013). Empirical Mode Decomposition-Based Time-Frequency Analysis of Multivariate Signals: The Power of Adaptive Data Analysis. *IEEE Signal Processing Magazine*, *30*(6), 74–86. doi:10.1109/MSP.2013.2267931
- Mandic, D., Souretis, G., Leong, W. Y., Looney, D., Van Hulle, M. M., & Tanaka, T. (2008). Complex Empirical Mode Decomposition for Multichannel Information Fusion BT - Signal Processing Techniques for Knowledge Extraction and Information Fusion. In D. Mandic, M. Golz, A. Kuh, D. Obradovic, & T. Tanaka (Eds.), (pp. 243–260). Boston, MA: Springer US. doi:10.1007/978-0-387-74367-7_13
- Maragos, P., Kaiser, J. F., & Quatieri, T. F. (1992). On separating amplitude from frequency modulations using energy operators. In *Acoustics, Speech, and Signal Processing, 1992. ICASSP-92., 1992 IEEE International Conference on* (Vol. 2, pp. 1–4 vol.2). doi:10.1109/ICASSP.1992.226135
- Marcano-Cedeño, A., Quintanilla-Domínguez, J., Cortina-Januchs, M. G., & Andina, D. (2010). Feature selection using Sequential Forward Selection and classification applying Artificial Metaplasticity Neural Network. In *IECON 2010 - 36th Annual Conference on IEEE Industrial Electronics Society* (pp. 2845–2850). doi:10.1109/IECON.2010.5675075
- Matsumoto, J., Omori, S., Nishiguchi, M., & Iijima, K. (1998). Voice encoding method and apparatus using modified discrete cosine transform. Google Patents.
- McLachlan, G., & Krishnan, T. (2007). *The EM algorithm and extensions* (Vol. 382). John Wiley & Sons.
- Molau, S., Pitz, M., Schlüter, R., & Ney, H. (n.d.). Computing Mel-Frequency Cepstral Coefficients On The Power Spectrum.
- MontalvãO, J., & Rodrigues Araujo, M. R. (2012). Is Masking a Relevant Aspect Lacking in MFCC? A Speaker Verification Perspective. *Pattern Recogn. Lett.*, *33*(16), 2156–2165. doi:10.1016/j.patrec.2012.07.023
- Morchid, M., Dufour, R., Bousquet, P.-M., Linares, G., & Torres-Moreno, J.-M. (2014). Feature selection using Principal Component Analysis for massive retweet detection. *Pattern Recognition Letters*, *49*, 33–39. doi:<http://dx.doi.org/10.1016/j.patrec.2014.05.020>

- Müller-Karger, C., Wong, S., & La Cruz, A. (2008). *IV congreso Latinoamericano de ingeniería biomédica, CLAIB 2007, soluciones de bioingeniería para la salud en América Latina. IFMBE Proceedings* (Vol. 18). Springer Verlag. doi:10.1007/978-3-540-74471-9
- Ng, H. T., Goh, W. B., & Low, K. L. (1997). Feature Selection, Perceptron Learning, and a Usability Case Study for Text Categorization. In *Proceedings of the 20th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval* (pp. 67–73). New York, NY, USA: ACM. doi:10.1145/258525.258537
- Nikolic-Doric, E., Cobanovic, K., & Lozanov-Crvenkovic, Z. (2006). Statistical Graphics And Experimental Data. *ICOTS-7*.
- Oliveira, P. M., & Barroso, V. (2000). Definitions of Instantaneous Frequency under physical constraints. *Journal of the Franklin Institute*, 337(4), 303–316. doi:http://dx.doi.org/10.1016/S0016-0032(00)00029-6
- Orrego, D., & Delgado, E. (2011). Representación efectiva de dinámicas fisiológicas mediante fuzzy rough set : una revisión. *ITECKNE*, 8, 204–215.
- Papadaniil, C. D., & Hadjileontiadis, L. J. (2014). Efficient Heart Sound Segmentation and Extraction Using Ensemble Empirical Mode Decomposition and Kurtosis Features. *IEEE Journal of Biomedical and Health Informatics*, 18(4), 1138–1152. doi:10.1109/JBHI.2013.2294399
- Papandreou-Suppappola, A. (2002). *Applications in time-frequency signal processing* (Vol. 10). CRC press.
- Park, C., Looney, D., Kidmose, P., Ungstrup, M., & Mandic, D. P. (2011). Time-Frequency Analysis of EEG Asymmetry Using Bivariate Empirical Mode Decomposition. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 19(4), 366–373. doi:10.1109/TNSRE.2011.2116805
- Patel, I., & Rao, Y. S. (2010). Speech Recognition Using HMM With Mfcc - An Analysis Using Frequency Spectral. *Signal & Image Processing: An International Journal(SIPIJ)*, 1(2), 101–110.
- Pattaraintakorn, P., & Cercone, N. (2008). A foundation of rough sets theoretical and computational hybrid intelligent system for survival analysis. *Computers and Mathematics with Applications*, 56(7), 1699–1708. doi:10.1016/j.camwa.2008.04.030
- Perk, J., De Backer, G., Gohlke, H., Graham, I., Reiner, Ž., Verschuren, M., ... Wolpert, C. (2012, July 1). European Guidelines on cardiovascular disease prevention in clinical practice (version 2012). *European Heart Journal*. doi:10.1093/eurheartj/ehs092

- Phua, K., Chen, J., Dat, T. H., & Shue, L. (2007). Heart sound as a biometric. *Pattern Recognition*, 41(3), 906–919. doi:10.1016/j.patcog.2007.07.018
- Pinzón, R., Orozco, A., & Castellanos, G. (2009). Caracterización multicanal no lineal de señales EMG con la transformada Hilbert-Huang. *Scientia et Technica*, XV(41), 36–41.
- Pudil, P., Novovičová, J., & Kittler, J. (1994). Floating search methods in feature selection. *Pattern Recognition Letters*, 15(11), 1119–1125. doi:http://dx.doi.org/10.1016/0167-8655(94)90127-9
- Rabiner, L. (1989). A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition. *Proceedings of the IEEE*, 77(2), 257–286.
- Rabiner, L., & Juang, B.-H. (1993). Fundamentals of speech recognition.
- Rabiner, L. R., & Schafer, R. W. (1978). *Digital Processing of Speech Signals*. Englewood Cliffs, NJ: Prentice-Hall. Retrieved from citeulike-article-id:4488402
- Rangayyan, R. M. (2004). *Biomedical image analysis*. CRC press.
- Reeves, S. J., & Zhe, Z. (1999). Sequential algorithms for observation selection. *IEEE Transactions on Signal Processing*, 47(1), 123–132. doi:10.1109/78.738245
- Rehman, N., & Mandic, D. P. (2010). Multivariate empirical mode decomposition. *Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, 466(2117), 1291–1302.
- Reynolds, D. A., & Rose, R. C. (1995). Robust text-independent speaker identification using Gaussian mixture speaker models. *IEEE Transactions on Speech and Audio Processing*, 3(1), 72–83. doi:10.1109/89.365379
- Rijsbergen, C. J. Van. (1979). *Information Retrieval* (2nd ed.). Newton, MA, USA: Butterworth-Heinemann.
- Rilling, G., Flandrin, P., Gon, P., & Lyon, D. (2003). On Empirical Mode Decomposition and Its Algorithms. *IEEE EURASIP Workshop on Nonlinear Signal and Image Processing NSIP*, 3, 8–11.
- Rivera, A. E. B. de la. (2012). *Análisis de Codificaciones Perceptuales de la Voz y su Comparación en el Reconocimiento de Comandos*. Universidad Nacional Autónoma de México.
- Roy, A. K., & Misal, A. (2014). Comparative Evaluation for Classification of PCG Signals using KNN Technique for Wavelet Transforms. *International Journal of Research in Engineering Technology and Management*.

- Sakamoto, T., Kusakawa, R., Maccanon, D. M., Luisada, A. A., & Harvey, I. (1965). Hemodynamic Determinants of the Amplitude of the First Heart Sound. *Circulation Research*, 16(1), 45–57. doi:10.1161/01.RES.16.1.45
- Salud, O. M. (2013). Centro de prensa Enfermedades cardiovasculares. Retrieved from <http://www.who.int/mediacentre/factsheets/fs317/es/>
- Sanei, S., Ghodsi, M., & Hassani, H. (2011). An adaptive singular spectrum analysis approach to murmur detection from heart sounds. *Medical Engineering & Physics*, 33(3), 362–367. doi:http://dx.doi.org/10.1016/j.medengphy.2010.11.004
- Sanei, S., & Hassani, H. (2015). *Singular Spectrum Analysis of Biomedical Signals*. CRC Press.
- Schlotthauer, G., Torres, M. E., & Rufiner, H. L. (2009). Determinación de la frecuencia fundamental de la voz basada en descomposición modal empírica por conjuntos y entropías. In *XIII Reunión de Trabajo en Procesamiento de la Información y Control* (pp. 0–5).
- Shannon, C. E. (2001). A Mathematical Theory of Communication. *SIGMOBILE Mob. Comput. Commun. Rev.*, 5(1), 3–55. doi:10.1145/584091.584093
- Shimpi, S., & Patil, V. (2013). Hidden Markov Model as Classifier: A survey, 13530–13533.
- Sinha, R. K., Aggarwal, Y., & Das, B. N. (2007). Backpropagation Artificial Neural Network Classifier to Detect Changes in Heart Sound Due to Mitral Valve Regurgitation. *J. Med. Syst.*, 31(3), 205–209. doi:10.1007/s10916-007-9056-1
- Soacha, E. A. C. (2005). *Caracterización de estados funcionales en fonocardiografía empleando análisis acústico y técnicas de dinámica no lineal*. Universidad Nacional de Colombia.
- Somol, P., Novovičová, J., & Pudil, P. (2006). Flexible-hybrid sequential floating search in statistical feature selection. In *Joint IAPR International Workshops on Statistical Techniques in Pattern Recognition (SPR) and Structural and Syntactic Pattern Recognition (SSPR)* (pp. 632–639).
- Tan, M., Pu, J., & Zheng, B. (2014). Optimization of breast mass classification using sequential forward floating selection (SFFS) and a support vector machine (SVM) model. *International Journal of Computer Assisted Radiology and Surgery*, 10.1007/s11548-014-0992-1. doi:10.1007/s11548-014-0992-1
- Tanaka, T., & Mandic, D. P. (2007). Complex Empirical Mode Decomposition. *IEEE Signal Processing Letters*, 14(2), 101–104. doi:10.1109/LSP.2006.882107

- Tong, S., Bezerianos, A., Paul, J., Zhu, Y., & Thakor, N. (2002). Nonextensive entropy measure of EEG following brain injury from cardiac arrest. *Physica A: Statistical Mechanics and Its Applications*, 305(3-4), 619–628. doi:10.1016/S0378-4371(01)00621-5
- Torres, M. E., Colominas, M. A., Schlotthauer, G., & Flandrin, P. (2011). A complete ensemble empirical mode decomposition with adaptive noise. In *2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. doi:10.1109/ICASSP.2011.5947265
- Tseng, Y.-L., Ko, P.-Y., & Jaw, F.-S. (2012). Detection of the third and fourth heart sounds using Hilbert-Huang transform. *BioMedical Engineering OnLine*, 11(1), 8. doi:10.1186/1475-925X-11-8
- Turkoglu, I., Arslan, A., & Ilkay, E. (2002). An expert system for diagnosis of the heart valve diseases. *Expert Systems with Applications*, 23(3), 229–236.
- ur Rehman, N., & Mandic, D. P. (2011). Filter Bank Property of Multivariate Empirical Mode Decomposition. *IEEE Transactions on Signal Processing*, 59(5), 2421–2426. doi:10.1109/TSP.2011.2106779
- Wang, J., Zhang, J., & Liu, Z. (2008). EMD based multi-scale model for high resolution image fusion. *Geo-Spatial Information Science*, 11, 31–37.
- Wang, Y.-H., Yeh, C.-H., Young, H.-W. V., Hu, K., & Lo, M.-T. (2014). On the computational complexity of the empirical mode decomposition algorithm. *Physica A: Statistical Mechanics and Its Applications*, 400(300), 159–167. doi:10.1016/j.physa.2014.01.020
- Wang, Z., Zhang, Q., & Zhang, D. (2007). A PSO-Based Web Document Classification Algorithm. In *Eighth ACIS International Conference on Software Engineering, Artificial Intelligence, Networking, and Parallel/Distributed Computing (SNPD 2007)* (pp. 659–664). IEEE. doi:10.1109/SNPD.2007.72
- Wong, T.-T. (2015). Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation. *Pattern Recognition*, 48(9), 2839–2846. doi:http://dx.doi.org/10.1016/j.patcog.2015.03.009
- Wu, Z., & Huang, N. E. (2009). Ensemble empirical mode decomposition: a noise-assisted data analysis method. *Advances in Adaptive Data Analysis*, 1(01), 1–41.
- Xin, L., & Xiang, L. (2010). Novel Hilbert Energy Spectrum Based Features for Speech Emotion Recognition. *Information Engineering (ICIE), 2010 WASE International Conference on*, 1, 189–193.

- Xue, L., Yin, J., Ji, Z., & Jiang, L. (2006). A Particle Swarm Optimization for Hidden Markov Model Training. In *2006 8th international Conference on Signal Processing* (Vol. 1). doi:10.1109/ICOSP.2006.345542
- Yao, H., Ma, J., & Dong, M. (2014). A Study of Heart Sound Analysis Techniques for Embedded-Link e-Health Applications. *International Conference on Intelligent Systems, Data Mining and Information Technology (ICIDIT'2014)*, 10–14.
- Yao, Y. Y. (1998). Relational interpretations of neighborhood operators and rough set approximation operators. *Information Sciences*, *111*(1), 239–259.
- Yu Lu, L. (2011). Equivalent Effect Function and Fast Intrinsic Mode Decomposition. *arXiv Preprint arXiv:1105.4337*, 1–12.
- Zadeh, L. (1975). The concept of a linguistic variable and its application to approximate reasoning - part I. *Information Sciences*, *8*, 199–249.
- Zhang, H. (2004). The optimality of naive Bayes. *AA*, *1*(2), 3.
- Zhao, Z., Luo, Y., Ren, F., Zhang, L., & Shi, C. (2013). Adaptive Analysis of Diastolic Murmurs for Coronary Artery Disease Based on Empirical Mode Decomposition. In *Adaptive Filtering - Theories and Applications* (Electrical.). February 20, 2013. doi:10.5772/55690
- Zhidong, Z., Zhijin, Z., & Yuquan, C. (2005). Time-frequency analysis of heart sound based on HHT [Hilbert-Huang transform]. In *Proceedings. 2005 International Conference on Communications, Circuits and Systems, 2005.* (Vol. 2, p. 929). doi:10.1109/ICCCAS.2005.1495260