

**Universitat de València**

**Escuela Técnica Superior de Ingeniería**

**Programa Doctorado en Ingeniería Electrónica**



VNIVERSITAT  
DE VALÈNCIA

**TESIS DOCTORAL**

**Análisis de Señales Biomédicas para  
Aplicación de Terapias en la Fibrilación  
Ventricular Cardíaca**

Autor: Azeddine Mjahad

Director: Alfredo Rosado Muñoz

**Mayo, 2017**

## Agradecimientos

Me gustaría que estas palabras plasmadas sirvan para expresar mi más sincero agradecimiento principalmente a Dios y todas las personas que durante estos cuatro años de tesis doctoral, me han ayudado, guiado, y aconsejado.

Gracias al Grupo de Procesado y Diseño Digitales–GPDD de la Universitat de València por acogerme en medio de ellos y darme la oportunidad de realizar esta investigación, en especial mi profundo agradecimiento al doctor Alfredo Rosado Muñoz por haber asumido la dirección de esta tesis doctoral, y quien ha sido siempre para mí una gran fuente de estimulación intelectual. Gracias por su supervisión, orientación, consejos y por ofrecerme su apoyo científico siempre con gran responsabilidad ya que sin su incondicional y constante motivación no estaría escribiendo ahora esta página.

A los doctores Juan Francisco Guerrero Martínez, Manuel Bataller Mompean y José Vicente Francés Villora por la revisión de los artículos científicos, sus consejos y valiosas aportaciones que me han servido para mejorar mis conocimientos y superación profesional.

A mis compañeros de laboratorio por la retroalimentación de conocimientos, amistad y colaboración.

A la Universitat de València la concesión de una beca de residencia que me ha permitido avanzar en mi investigación.

Me gustaría agradecer también a los profesores que han realizado la corrección de este trabajo y al jurado que me ha hecho el honor de aceptarlo para evaluar.

Mis apreciados amigos quienes me han estimulado y han estado siempre junto a mí durante todo este camino luchado. Ha sido un honor intercambiar nuestras experiencias, y sería un placer seguir así en el futuro.

Finalmente, otorgo esta tesis como un regalo a mis padres dejando constancia del infinito cariño que siento por ellos, a mis hermanos les debo muchos años de amor incondicional, apoyo, paciencia y superación personal.

## Resumen

La muerte súbita es una muerte natural, inesperada y rápida en un tiempo límite de 24 horas después del comienzo de un proceso patológico. Las causas más comunes de la muerte súbita son las enfermedades Cardiovasculares (ECV) que resultan estar entre las principales causas de muerte en todo el mundo. En 2012, la Organización Mundial de la Salud (OMS) registró 17,5 millones de muertes por ECV, que representan el 31 % de todas las muertes registradas en el mundo<sup>1</sup>.

Una de las enfermedades cardiovasculares con mayor mortalidad es la Fibrilación Ventricular (FV), que es una arritmia cardíaca producida por una actividad eléctrica desorganizada del corazón. Durante la FV, los ventrículos se contraen de forma asíncrona con ausencia de latido efectivo, fallando el bombeo sanguíneo, lo que produce la muerte súbita en el paciente, si no se trata de forma adecuada en un plazo de pocos minutos. La desfibrilación es el único tratamiento definitivo posible de la FV, que consiste en la aplicación de un choque eléctrico de alta energía sobre el pecho del paciente, facilitando así el reinicio de la actividad eléctrica cardíaca normal. El éxito de la desfibrilación es inversamente proporcional al intervalo de tiempo desde el comienzo del episodio hasta la aplicación de la descarga.

Aparecen muchas dificultades a la hora de diagnosticar la FV: por una parte están las características intrínsecas de la FV (falta de organización, irregularidad, etc.), y por otra, la gran similitud entre la FV y otras patologías cardíacas entre ellas la Taquicardia Ventricular (TV).

La diferenciación entre la TV y la FV es bastante complicada: el diagnóstico de la TV como FV en un paciente puede ocasionarle graves lesiones a la hora de aplicarle la terapia correspondiente a FV (descarga eléctrica de alto voltaje), es más, puede causarle una FV.

Por el contrario, si la FV se interpreta incorrectamente como TV, el resultado puede ser también peligroso para la vida. Por lo tanto, un método de detección eficaz para distinguir FV de TV tiene mucha importancia en la investigación clínica.

Con el fin de diagnosticar y tratar las enfermedades cardiovasculares (FV por ejemplo), se establecen dos grandes grupos de métodos diagnósticos en cardiología: métodos diagnósticos invasivos y no invasivos. Las técnicas invasivas requieren introducir catéteres en el organismo,

---

<sup>1</sup> "<http://www.who.int/mediacentre/factsheets/fs317/es/>".

con el objetivo de medir presiones de las cavidades cardíacas, para registrar la actividad eléctrica. Las técnicas no invasivas están enfocadas a caracterizar el estado fisiopatológico del corazón a través de electrodos colocados directamente sobre la piel del paciente.

El electrocardiograma (ECG) es un examen no invasivo, de bajo costo, que se ha utilizado como el método básico de diagnóstico de desórdenes cardíacos de conducción eléctrica, mediante el estudio de la frecuencia cardíaca y la morfología de diferentes ondas que constituyen el ciclo cardíaco. El análisis ECG constituye una buena fuente de información a partir de la cual se pueden detectar diferentes tipos de enfermedades cardíacas.

Debido a que la señal de ECG es una señal aleatoria no estacionaria, el análisis en el dominio del tiempo no resulta ser suficientemente sensible a las distorsiones de las formas de la onda ECG. Sin embargo estos métodos no siempre presentan todas las informaciones que pueden ser extraídas de las señales ECG, con lo cual, se pierde la información sobre la frecuencia, la cual muestra una información más adicional de la señal. El diagnóstico en el dominio de la frecuencia utiliza métodos como la transformada de Fourier. Por lo tanto, el análisis en el dominio de la frecuencia permite determinar las frecuencias de la señal. Por otro lado, se pierde la información de tipo temporal de la señal, con lo cual es un método muy limitado y no es útil para el análisis de señales no estacionarias. Varios estudios han utilizado modelos matemáticos que combinan la información temporal y espectral en la misma representación. Esta técnica Representación Tiempo-Frecuencia (RTF) es muy importante en el tratamiento de las señales no estacionarias como la señal de ECG, ya que distribuye la energía de la señal en el espacio bidimensional tiempo-frecuencia. Además, múltiples factores alteran la adquisición y registro de la señal ECG: por un lado está la influencia del medio ambiente (la interferencia de red 50-60 Hz, la línea base, etc.), y por otro lado están las perturbaciones de origen fisiológico como los de la electromiografía (EMG).

La reducción del ruido en el ECG ha sido uno de los principales campos de investigación en las últimas décadas, ya que una adecuada reducción permite realizar un buen pre-procesado de la señal, extrayendo de ésta la máxima cantidad de información posible y eliminando la no deseable.

El uso de imágenes de representación de tiempo-frecuencia (t-f) como la entrada directa al clasificador es lo novedoso de esta tesis doctoral. Se plantea la hipótesis de que este método

facilita mejorar los resultados de la clasificación ya que permite eliminar la extracción de características típicas, y su correspondiente pérdida de información, que además se utilizan para la evaluación y la comparación con otros autores.

**Materiales y Métodos:** se ha utilizado las bases de datos estándar del MIT-BIH *Malignant Ventricular Arrhythmia Data base* y AHA (2000 series) para obtener los registros de las señales ECG, creando a partir de ellos un conjunto de entrenamiento y uno de prueba para los algoritmos de clasificación empleados. Un total de 24 registros de monitorización continua (22 registros de MIT-BIH más dos adicionales de la base de datos AHA) se ha empleado, con frecuencia de muestreo de 125 Hz.

Como método se ha implementado un algoritmo de filtro, con el fin de reducir la línea base, se desarrolla un inventariado que indica el comienzo de la Ventana de tiempo ( $V_t$ ) de la señal del ECG. A cada ventana obtenida se le aplicó la Transformada de Hilbert (TH), después se le aplicó la RTF como entrada a los cinco clasificadores: las Redes Neuronales Artificiales de clasificación (ANNC-*Artificial Neural Networks Classification*), máquina de vector de soporte de tipo Smooth (SSVM-*Smooth Support Vector Machine*), (BAGG-*Bagging*), regresión logística (L2\_RLR-*L<sub>2</sub>-Regularized Logistic Regression*) y K vecinos más cercanos (KNN-*K Nearest Neighbors*). Se realizó sus respectivos entrenamientos y pruebas individuales eligiendo el clasificador KNN por su mejor calidad de detección. La RTF fue convertida en Imagen de RTF (IRTF) e IRTF de dimensionalidad reducida mediante técnicas de reducción del tamaño de imágenes (Media de la Intensidad de los Píxeles (MIP), KNN, Bilineal, Bicúbica) y de la técnica de Selección de Características (SC) de tipo (SFS-*Sequential Forward Selection*).

Se realizaron combinaciones de los algoritmos de clasificación al aplicarse sobre un mismo conjunto de datos (IRTF, IRTF reducida, SC), con el fin de comparar el comportamiento entre ellos y con los resultados logrados de los clasificadores individuales. Estas estrategias y metodologías utilizadas fueron comparadas con diferentes métodos citados en la bibliografía y así comprobar en qué medida los resultados obtenidos apoyan nuestra hipótesis.

**Resultados:** usando parámetros de evaluación del rendimiento (sensibilidad, especificidad y exactitud) como metodología para validar los resultados que obtuvo cada una de las estrategias empleadas, se encontró que el clasificador KNN alcanza el mejor rendimiento para RTF. Se logró para 'FV' una sensibilidad del 94,97% y una especificidad global del 99,27%, exactitud

global del 98,47 %, y para ‘TV’ una sensibilidad del 93,47%, especificidad global del 99,39%, exactitud global del 98,97% y un tiempo de ejecución 0,1763s.

Los principales resultados de la clasificación para la detección de FV obtenidos usando la técnica IRTF reducida (MIP) como entrada al clasificador KNN, mostraron un 88,27% de sensibilidad, 98,22% de especificidad global y 96,35% de exactitud global. En el caso de ‘TV’ 88,31% de sensibilidad, 98,80% de especificidad global, 98,05% de exactitud global y un tiempo de ejecución 0,024s.

Al realizar combinaciones de los clasificadores, se obtuvo que la combinación ANNC\_KNN\_ANNC al utilizar el Método de Jerárquica (MJ) dieron una sensibilidad del 92,14%, especificidad del 98,07% y 97,07% de exactitud global para ‘FV’, una sensibilidad del 89,03%, una especificidad del 80,78%, 98,08% de exactitud global para ‘TV’ y un tiempo de ejecución entre [0,0239s; 0,0241s].

**Conclusiones:** la clasificación realizada en la discriminación de FV y TV demostró cómo se comportan los distintos algoritmos de clasificación tanto individuales como combinados al aplicarse sobre un mismo conjunto de características.

Los resultados obtenidos mediante el algoritmos de combinación ANNC\_KNN\_ANNC usando los datos de IRTF reducidas fueron mejores en la detección comparado con los obtenidos mediante los algoritmos utilizados individualmente y otros multclasificadores aplicando sobre un mismo conjunto de datos de IRTF reducidas.

Además al comparar los resultados de la combinación con los obtenidos mediante KNN empleando la RTF y IRTF no reducidas son ligeramente inferiores en combinación, pero en cambio se obtiene un tiempo de ejecución menor, por lo que es de mejor utilidad para sistemas de detección en tiempo real.

Después de un largo análisis es posible concluir que la metodología propuesta brinda información útil para la detección de FV con un bajo tiempo de cómputo, la cual la puede separar satisfactoriamente del resto de patologías cardiacas a la hora de diagnosticar, mejorando significativamente las posibilidades del paciente de ser manejado eficazmente al presentar un episodio con alguna de estas arritmias, lo que convierte a este trabajo en una fuente de aporte clínico en la ayuda para el diagnóstico de arritmias.

## Objetivo general

El objetivo general es desarrollar un nuevo sistema de diagnóstico automático eficiente para la detección en tiempo real de la aparición de la fibrilación ventricular mediante métodos de tiempo-frecuencia usada como entrada directa a un clasificador basado en el aprendizaje automático, sin necesidad de ningún parámetro extraído.

Para llevar a cabo este objetivo general se realizó estudios comparativos en cada una de las fases del pre-procesamiento de la señal del ECG, también estudios comparativos de estrategias usadas en la extracción de la información y clasificación. Para lo cual se han desarrollado varios objetivos específicos de análisis, que ayudan a obtener resultados confiables para cada una de las etapas. Estos objetivos específicos son:

- Eliminar la interferencia de red (50 o 60 Hz), de la línea base y del electromiograma (EMG).
- Desarrollar un algoritmo que permita poner las marcas de referencias para las ventanas de la señal (ECG) a partir del cual se calcula la TH para luego aplicar la RTF.
- Reducir la dimensionalidad de los datos de RTF usando diferentes estrategias como la extracción de imagen equivalente a la RTF y SC.
- Comparar los resultados obtenidos entre los clasificadores individuales y combinados usando RTF y las estrategias de reducción de dimensionalidad.

Las pruebas se realizan sobre las bases de datos estándar MIT-BIH utilizando parámetros de comparación habituales (sensibilidad, especificidad y exactitud), con el fin de evaluar los resultados obtenidos con los métodos implementados en este trabajo con respecto a los resultados obtenidos con otros métodos propuestos.

## Organización del Documento

Para alcanzar los objetivos propuestos en la presente tesis doctoral, el trabajo se organizó en 7 capítulos de la siguiente manera: El capítulo 1 se dedica a introducir el elemento principal del sistema cardiovascular; el funcionamiento del corazón, las principales características de señal electrocardiograma ECG, sus ondas componentes, y tipos de derivaciones. En el capítulo 2 se realiza una descripción de Ritmos. El capítulo 3 está dedicado a la descripción del conjunto de datos MIT-BIH usados, materiales y métodos propuestos, se describen las perturbaciones en las señales, las técnicas de pre-procesamiento de la señal ECG, representación tiempo frecuencia y los diferentes métodos para la extracción de información. En el capítulo 4 se presenta un estudio centrado en los resultados de diferentes algoritmos de clasificación individuales usando diferentes métodos. En el capítulo 5, se realizan diferentes métodos de combinaciones entre los clasificadores individuales. En el capítulo 6, se realiza un análisis comparativo de diferentes tipos de estrategias consideradas individuales, combinaciones, y de otros trabajos de la bibliografía. Finalmente se presentan las conclusiones.

## **Índice general**

# Contenido

<i>Índice general</i>	9
<i>Abreviaturas:</i>	14
<i>Notaciones:</i>	18
<i>Capítulo 1. Funcionamiento del corazón y técnicas de diagnóstico en cardiología</i>	19
<b>1.1 Sistema cardiovascular</b>	19
1.1.1 Anatomía y Fisiología del Corazón	20
1.1.2 Sistema de conducción	23
1.1.3 Propiedades electrofisiológicas de las células cardíacas	25
<b>1.2 Técnicas de diagnóstico en cardiología</b>	26
1.2.1 Técnicas invasivas	26
1.2.2 Técnicas no invasivas	27
<b>1.3 Interpretación de las ondas componentes del ECG</b>	28
1.3.1 Electrocardiografía	28
1.3.2 Sistema de derivaciones electrocardiográficas	28
1.3.2.1 Derivaciones del plano frontal	28
1.3.2.2 Derivaciones precordiales o derivaciones del plano horizontal	31
1.3.3 Registro de la actividad	31
1.3.3.1 Ondas, segmentos e intervalos del ECG	31
1.3.3.2 Frecuencia cardíaca	33
<i>Capítulo 2. Ritmos cardíacos</i>	34
<b>2.1 Ritmo sinusal normal (Ritmo Normal)</b>	34
<b>2.2 Arritmias cardíacas</b>	35
2.2.1 Arritmias ventriculares	36
2.2.1.1 Extrasístoles ventriculares	36
2.2.1.2 Taquicardia ventricular	37
2.2.1.3 Flutter y fibrilación ventricular	38
<b>2.3 Desfibrilación y cardioversión</b>	40

2.3.1 Tratamiento de FV _____	40
2.3.2 Dispositivo de desfibrilación _____	41
2.3.2.1 Desfibriladores externos _____	41
2.3.2.2 Desfibriladores interno automático _____	42
2.3.3 Las diferencias entre tratamiento de FV y TV _____	42
<i>Capítulo 3. Procesamiento de la señal electrocardiográfica (ECG) _____</i>	<b>43</b>
<b>3.1 Introducción _____</b>	<b>43</b>
<b>3.2 Materiales _____</b>	<b>45</b>
3.2.1 Base de datos de señales electrocardiográficas de Physiobank _____	45
3.2.2 Descripción de la base de datos _____	46
<b>3.3 Procesado de la señal ECG _____</b>	<b>47</b>
3.3.1 Técnicas de pre-procesamiento de la señal ECG _____	48
3.3.1.1 Métodos para la reducción de las variaciones de la línea base _____	49
3.3.1.2 Métodos para la reducción de la interferencia de red (50 Hz, 60Hz) _____	49
3.3.1.3 Métodos para la reducción de diversas fuentes de ruido _____	50
3.3.1.4 Filtros para eliminar la línea base _____	51
3.3.1.5 Enventanado de ECG para detección de FV _____	57
3.3.1.6 Marcas de referencia de ventana MRV _____	58
3.3.2 Representación RTF _____	61
3.3.2.1 Introducción _____	61
3.3.2.2 Aplicación del análisis tiempo-frecuencia _____	62
3.3.2.2.1 Transformada de Fourier _____	62
3.3.2.2.2 Densidad de energía en tiempo y frecuencia: _____	63
3.3.2.3 La señal analítica _____	64
3.3.2.4 Principio de incertidumbre de heisenberg _____	65
3.3.2.5 Definiciones y propiedades de las RFT _____	66
3.3.3 Extracción de la información de RTF e IRTF _____	81
3.3.3.1 Extracción de la información mediante RTF _____	82
3.3.3.2 Extracción de la información mediante IRTF _____	83
3.3.3.2.1 Media de la intensidad de los píxeles _____	85
3.3.3.2.2 Interpolación _____	86

3.3.3.2.3 Selección de características	86
3.4 Clasificación	86
<i>Capítulo 4. Algoritmos de clasificación para la detección de FV</i>	<i>88</i>
4.1 Aprendizaje automático	88
4.2 Métodos de Clasificación	90
4.2.1 Clasificador de K vecinos más cercanos	90
4.2.2 Máquinas de vectores de soporte	91
4.2.3 Agregación bootstrap o bagging	93
4.2.4 Regresión logística	93
4.2.5 Redes Neuronales Artificiales	94
4.3 Entrenamiento	96
4.4 Arquitectura del procedimiento de clasificación	96
4.4.1 Parámetros de los clasificadores	97
4.4.2 Validación cruzada	98
4.5 Parámetros de evaluación	98
4.6 Etapas de pruebas	99
4.7 Clasificación mediante análisis de RTF	102
4.7.1 Análisis continuo	102
4.7.2 Marcas de Referencias de las Ventanas	107
4.7.2.1 Análisis basado en diferentes tipos de algoritmos de clasificación	107
4.7.2.2 Análisis basado en varios tipos de RTF usando el algoritmo KNN	111
4.7.2.3 Análisis basados en varios filtros de la línea base usando el algoritmo KNN	113
4.8 Clasificación por la conversión RTF a imagen IRTF	115
4.8.1 IRTF de tamaño reducido.	115
4.8.2 Selección de características	118
<i>Capítulo 5. Métodos de clasificación combinados</i>	<i>123</i>
5.1 Las topologías de combinación	124

<b>5.2 Estudio comparativo de los diferentes métodos de clasificación combinados</b>	<b>125</b>
<b>5.2.1 Prueba usando los datos IRTF no reducida.</b>	<b>126</b>
<b>5.2.2 Pruebas usando los datos IRTF reducida</b>	<b>130</b>
<b>5.2.2.1 Pruebas usando MIP</b>	<b>130</b>
<b>5.2.2.2 Pruebas usando SC</b>	<b>132</b>
<i>Capítulo 6. Comparación entre las diferentes estrategias</i>	<b>135</b>
<i>Capítulo 7. Conclusiones</i>	<b>145</b>
<i>Bibliografía</i>	<b>149</b>
<i>Índice de Figuras</i>	<b>164</b>
<i>Índice de Tablas</i>	<b>167</b>

## Abreviaturas:

Notación	Significado
ECV	Enfermedades Cardiovasculares
OMS	Organización Mundial de la Salud
ECG	Electrocardiograma
EMG	Electromiograma
FL	Flutter ventricular
FV	Fibrilación Ventricular
TV	Taquicardia Ventricular
Ritmo Normal	Ritmo sinusal normal
VI	Ventrículo izquierdo
VD	Ventrículo derecho
AI	Aurícula izquierda
AD	Aurícula derecha
SA	Sinoatrial
AV	Auriculoventricular
lpm	Latidos por minutos
TC	Tomografía Computada
RMN	Resonancia Magnética Nuclear
RxT	Radiografía de Tórax
VL	<i>Vector left</i>
VR	<i>Vector right</i>
VF	<i>Vector foot</i>
V <sub>R</sub>	Brazo derecho
V <sub>L</sub>	Brazo izquierdo
V <sub>F</sub>	Pie izquierdo

RTF	Representación Tiempo-Frecuencia
IRTF	Imagen de Representación Tiempo-Frecuencia
aVR	<i>augmented Vector Right</i>
aVL	<i>augmented Vector Left</i>
aVF	<i>augmented Vector Foot</i>
DEM	Desfibrilador Externo Manual
DESA	Desfibrilador Externo Semi-automático
DEA	Desfibrilador Externo Automático
DIA	Desfibriladores Interno Automático
AHA DB	<i>The American Heart Association Database for Evaluation of Ventricular Arrhythmia Detectors.</i>
MIT-BIH DB	<i>The Massachusetts Institute of Technology-Beth Israel Hospital Arrhythmia Database.</i>
IIR	<i>Infinite Impulse Response</i>
LMS	<i>Least Mean Squares.</i>
RLS	<i>Recursive Least-Squares</i>
V <sub>t</sub>	Ventana de tiempo
ML	Máximos Locales
MRV	Marcas de Referencia de Ventanas
MRV <sub>Min</sub>	Distancias mínima entre dos MRV consecutivos
MRV <sub>Max</sub>	Distancias máxima entre dos MRV consecutivos
N <sub>ML</sub>	Número de marcas de Máximos Locales
DML	Distancia entre dos ML consecutivos
DAG	Distancia Atípica Grande
DAP	Distancias Atípicas Pequeñas
DRM	Distancias Regular Medianas
N <sub>MLC</sub>	Número de marcas ML Corregidas

RTF	Representación Tiempo-Frecuencia
IRTF	Imagen de Representación Tiempo-Frecuencia
TF	Transformada de Fourier
TFD	<i>Time Frequency Distribution</i>
STFT	<i>Short Time Fourier Transform</i>
WT	<i>Wavelet-Transformation</i>
CWT	<i>Continuous Wavelet Transform</i>
DWT	<i>Discrete Wavelet Transform</i>
TFD	<i>Time-FrequencyDistribution</i>
WD	<i>WignerDistribution</i>
WVD	<i>Wigner-Ville Distribution</i>
PWV	<i>Pseudo Wigner-Ville</i>
PWVD	<i>Pseudo-Wigner-Ville Distribution</i>
SPWVD	<i>Smoothed Pseudo Wigner-Ville Distribution</i>
DBessel	<i>Distribution de Bessel</i>
CWD	<i>Choi-Williams Distribution</i>
BJD	<i>Born-Jordan Distribution</i>
MD	Matriz de Datos
MD'	Matriz de Datos de RTF
MD''	Matriz de Datos de IRTF
MD'''	Matriz de Datos de IRTF de tamaño reducido
LDA	<i>linear discriminant analysis</i>
MDS	<i>Mul-tidimensional Scaling</i>
PCA	<i>Principal Component Analysis</i>
MIP	Media de la Intensidad de los Píxeles
R <sub>nm</sub>	Rectángulo

$I_{\text{MediaPíxeles}_{nm}}$	Intensidad media de los píxeles en $R_{nm}$
$I_{\text{Pixel}_{kj}}$	Intensidad del pixel $_{kj}$
SC	Selección de características
$V_{sc}$	Subconjunto reducido de MD'' mediante SC
NC	Número de Características
SFS	<i>Sequential forward selection</i>
SBS	<i>Sequential backward selection</i>
Sens	Sensibilidad
Esp	Especificidad
Exa	Exactitud
ANN	Artificial Neural Networks
BAGG	<i>Bagging</i>
L2_RLR	<i>L<sub>2</sub>Regularized Logistic Regression</i>
KNN	<i>K Nearest Neighbors</i>
SVM	<i>Support Vector Machine</i>
SSVM	<i>Smooth Support Vector Machine</i>
MMV	Método Mayoría de Votos
ELM	<i>Extreme Learning Machines</i>
MJ	Método de Jerárquica

**Notaciones:**

<b>Notación</b>	<b>Significado</b>
$t$	Tiempo
$f$	Frecuencia
$\tau$	Retraso de tiempo
$\theta$	Retraso de frecuencia
$z(t)$	Señal compleja
$TH(x(t))$	Transformada de Hilbert de la señal $x(t)$
$x(t), T(t, f)$	Función continua
$x[n], T[n, k]$	Función discreta
$K \times J$	Tamaño del rectángulo $R_{nm}$
$L_a \times L_b$	Tamaño de $IRTF_{L_a \times L_b}$
El punto(n, m)	Localizar el rectángulo $R_{nm}$ en $IRTF_{L_a \times L_b}$ .
$K$	Vecinos más cercanos
$\emptyset$	<i>Kernel</i>
$D$	Conjunto de entrenamiento
$\lambda$	Parámetro de regularización

*La armonía de los componentes, segmentos y ondas en un electrocardiograma (ECG), nos describen un latido cardiaco normal. A partir de los cambios de la forma de la señal de un latido normal, se pueden identificar las diferentes patologías en el paciente, según son descritas posteriormente. A la hora de analizar, es importante estudiar el origen fisiológico de la señal del ECG. En la primera parte del capítulo 1, se hace una descripción general del sistema cardiovascular y una introducción de la anatomía del corazón humano, así como de su sistema de conducción eléctrica. En la segunda parte de este capítulo se describen las diferentes técnicas de diagnóstico en cardiología. En la tercera parte se describen las características de la señal del ECG, las formas de sus ondas, sus intervalos, y las bases teóricas del sistema de derivaciones.*

## **Capítulo 1. Funcionamiento del corazón y técnicas de diagnóstico en cardiología**

### **1.1 Sistema cardiovascular**

El sistema cardiovascular está formado por el corazón y los vasos sanguíneos como muestra la figura 1. Se trata de un sistema de transporte en que el corazón actúa como una bomba cuya función es recibir, expulsar y transportar la sangre a través de los vasos sanguíneos a todas las células del organismo, para que éstas obtengan el oxígeno, los nutrientes y otras sustancias necesarias [1].

Existen 3 tipos de vasos como se observa en la figura 1:

- Arterias: se originan a partir de los ventrículos y conducen la sangre desde el corazón hacia el resto del cuerpo.
- Venas: llegan a las aurículas transportando la sangre de retorno de todo el cuerpo hacia el corazón.
- Capilares: son los vasos por los cuales la sangre circula desde las arterias hacia las venas. En el mismo se produce el intercambio de gases, nutrientes y desechos.

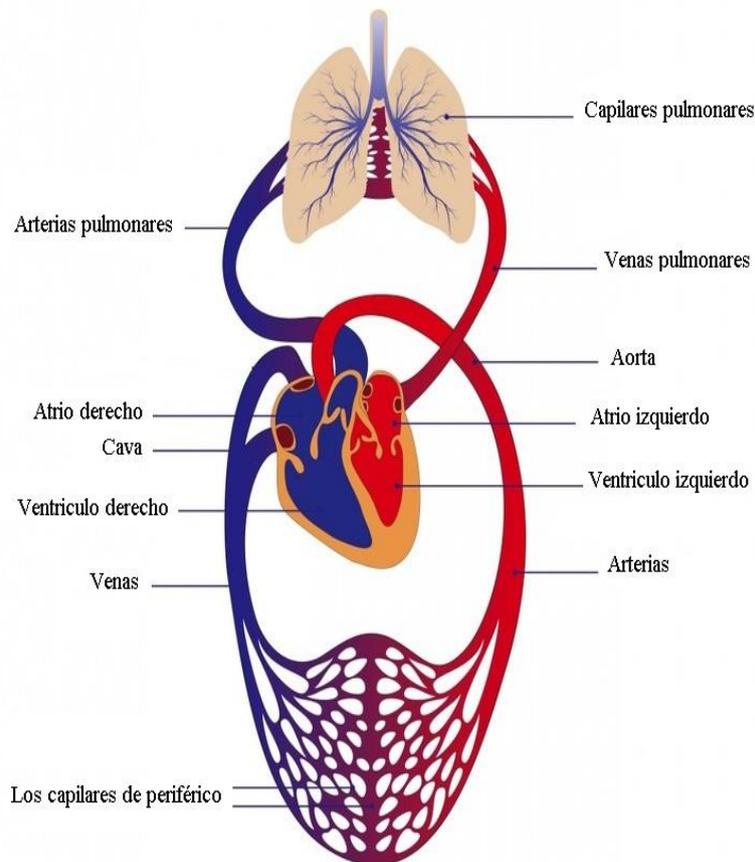


FIGURA 1. CIRCULACIÓN SISTÉMICA Y PULMONAR DE LA SANGRE<sup>1</sup>.

### 1.1.1 Anatomía y Fisiología del Corazón

En el cuerpo humano, el corazón es el órgano central del sistema cardiovascular con un peso aproximado de entre 200 y 350 g. En reposo, es capaz de propulsar entre 4 y 5 litros de sangre por minuto. Se encuentra ubicado en la cavidad torácica por detrás del esternón, entre los pulmones y por encima del diafragma.

El corazón se divide en dos partes independientes (la parte izquierda y la parte derecha). Cada una de las partes del corazón está compuesta por una cavidad auricular y una cavidad ventricular.

Las cavidades inferiores denominadas ventrículos, están formadas por el ventrículo izquierdo (VI), y el ventrículo derecho (VD) y separadas por el tabique interventricular, mientras que las

<sup>1</sup> “<http://www.medical-reference.net/>.”

cavidades superiores constan de la aurícula izquierda (AI) y la aurícula derecha (AD) que se encuentran separadas por el tabique interauricular [1]. Existen una serie de válvulas que controlan el flujo de la sangre dentro del corazón, las mismas que están situadas en la unión auriculoventricular y entre el ventrículo y las arterias de salida. Para el lado izquierdo corresponden las válvulas mitral y aórtica, mientras que para el lado derecho tenemos las válvulas tricúspides y la pulmonar. Las cuatro válvulas se describen a continuación (ver la figura 2) [1]:

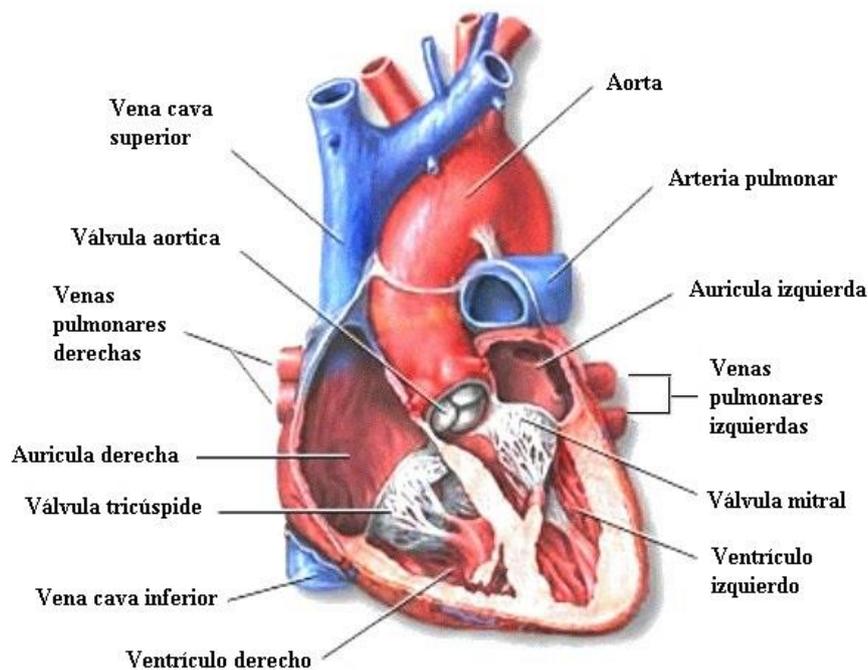


FIGURA 2. ANATOMÍA DEL CORAZÓN<sup>1</sup>.

- La válvula mitral o bicúspide, se encuentra entre la aurícula izquierda y el ventrículo izquierdo impidiendo que la sangre rica en oxígeno proveniente de los pulmones que pasa de aurícula izquierda al ventrículo izquierdo se regrese a la aurícula.
- La válvula tricúspide, se encuentra entre la aurícula y ventrículo derecho, su función es impedir que la sangre retorne a la aurícula una vez que pasa de aurícula a ventrículo.

<sup>1</sup>“<http://www.electrocardiografia.es/>.”

- La válvula pulmonar, se encuentra entre ventrículo derecho y arteria pulmonar e impide que la sangre depositada a la arteria pulmonar, retorne al ventrículo derecho.
- La válvula aórtica, su función es impedir que la sangre rica en oxígeno que pasa del ventrículo a la aorta, retorne al ventrículo izquierdo. Se encuentra ubicada entre el ventrículo izquierdo y la arteria aorta.

Del corazón salen arterias y regresan venas. A la AD llega la sangre carente de oxígeno de todo el cuerpo mediante la vena cava superior e inferior. El VD recibe la sangre no oxigenada de la AD por medio del agujero auriculoventricular derecho donde se encuentra la válvula tricúspide para ser expulsada fuera del corazón hacia los pulmones a través de la arteria pulmonar. Luego esta sangre es transportada hacia los capilares sanguíneos pulmonares donde se realiza el intercambio gaseoso (la sangre capta oxígeno y libera dióxido de carbono). Una vez oxigenada, la sangre retorna por las venas pulmonares a la AI.

El VI es quien impulsa la sangre rica en oxígeno hacia la arteria aorta, la cual lleva la sangre oxigenada a la mayor parte del cuerpo. Una vez que los diferentes órganos han captado el oxígeno de la sangre arterial, la sangre pobre en oxígeno vuelve a la mitad derecha del corazón a través de las venas cavas, entrando en la AD, (ver la figura2).

**Capas del corazón:** el corazón está formado por tres capas: el pericardio, el miocardio y el endocardio. Su principal función es proteger al corazón de infecciones y de influencias externas. El pericardio es una capa externa doblada a modo de saco que envuelve el corazón. A la capa media y más gruesa de la pared del corazón se la denomina miocardio, la cual está formada por fibras musculares estriadas cardíacas y miocardiocitos, y es en esta capa donde encontramos las células nodales y células de Purkinje que son las de conducción cardíaca que serán descritas posteriormente (ver sección 1.1.2) [2]. El endocardio es una capa interna muy fina que recubre los ventrículos y aurículas, así como las válvulas cardíacas.

### Ciclo cardíaco

El ciclo cardíaco presenta dos fases que duran aproximadamente un segundo. Una de contracción llamada **sístole** y otra de relajación llamada **diástole**. Una vez que los diferentes órganos han captado el oxígeno de la sangre arterial, la sangre pobre en oxígeno entra en el sistema venoso y retorna a la mitad derecha del corazón. El ciclo cardíaco (figura 3) puede describirse como [3] [4]:

**Diástole ventricular:** es el período en el cual los ventrículos están relajados, las válvulas de salida de los ventrículos (aórtica y pulmonar) deben estar cerradas, y las válvulas mitral y tricúspide de entrada al ventrículo tienen que estar abiertas.

**Sístole auricular:** se inicia con un potencial de acción en el nódulo sinusal que en un principio se propagará por las aurículas provocando su contracción. Al contraerse éstas, se expulsa toda la sangre que contienen hacia los ventrículos, las válvulas auriculoventricular (Mitral y Tricúspide) están abiertas, mientras que las válvulas sigmoideas (Aórtica y Pulmonar) se encuentran cerradas.

**Sístole ventricular:** es el período en el cual los ventrículos se contraen y provocan la eyección de la sangre por las arterias pulmonar y aorta. Las válvulas de salida de los ventrículos (aórtica y pulmonar) deben estar abiertas, mientras que las válvulas mitral y tricúspide deben estar cerradas, para que la sangre no regrese hacia las aurículas. El ciclo de contracciones comienza otra vez y se repite constantemente [4].

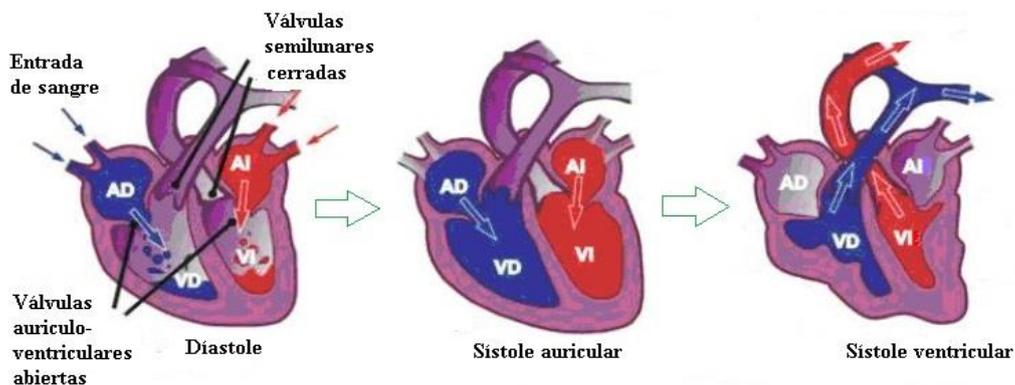


FIGURA 3. EL CICLO CARDÍACO [5].

### 1.1.2 Sistema de conducción

El corazón posee la facultad de contraerse y relajarse sin tener un estímulo directo del sistema nervioso, esto sucede debido a que el corazón tiene un sistema de regulación intrínseco llamado sistema de conducción, el cual se compone de un conjunto de células especializadas Nodo Sinusal, también llamado Sinoatrial (SA), Nodo Auriculoventricular (AV), Haz de His, Ramas

del Haz de His y Fibras Purkinje. La actividad eléctrica del corazón puede registrarse mediante un Electrocardiograma (ECG) como se detallaba en la sección 1.3.

**Nodo sinusal:** ubicado en la aurícula derecha, cerca de la desembocadura de la vena cava superior, constituido por un cúmulo de células especializadas para iniciar el impulso eléctrico, despolarizándose a una frecuencia entre 60 y 100 latidos por minuto en condiciones normales. El impulso eléctrico se desplaza rápidamente por ambas aurículas a través de las vías internodales formando la onda P en el registro del ECG.

Posteriormente, la onda eléctrica con la despolarización aurícula llega a otro grupo de células denominada nodo auriculoventriculas (AV), el cual activa como una marcapasos secundarios (ver la figura 4)

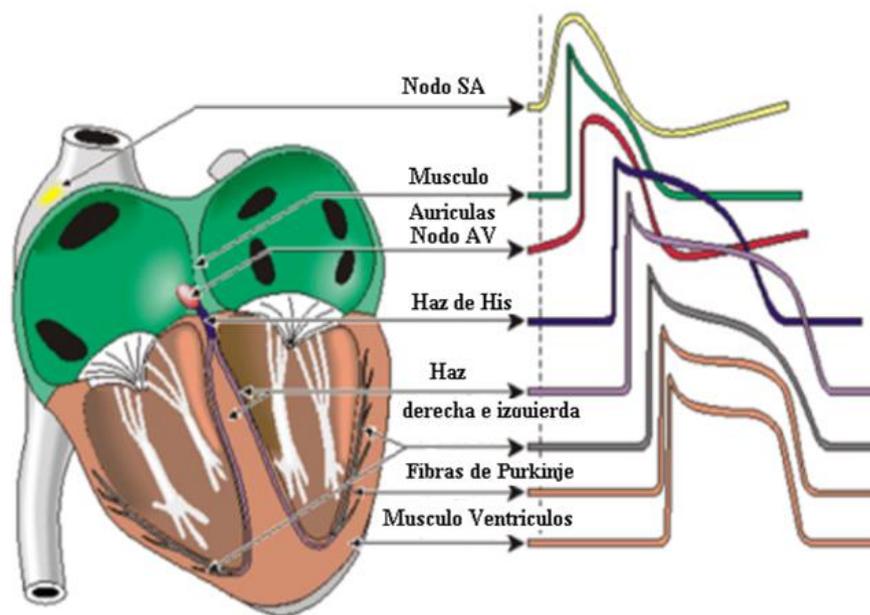


FIGURA 4. SISTEMA DE CONDUCCIÓN CARDÍACO Y SUS ONDAS CARACTERÍSTICAS [1].

**Nodo auriculoventricular:** está ubicado en la parte inferior del tabique interauricular, entre ambos ventrículos. Cuando la onda de activación eléctrica pasa por el nodo AV, sufre una pausa de aproximadamente una décima de segundo.

En este nodo, la velocidad de propagación es muy lenta, con una frecuencia de 40-60 pulsos por minuto. Esta frecuencia da lugar a un retraso de aproximadamente 0.1s en llevar a cabo la

contracción auricular antes que la contracción ventricular, representándose en el ECG como el intervalo PR.

El impulso cardíaco se disemina luego a través del Haz de His, que es un conjunto de fibras a manera de un puente entre el nódulo auriculoventricular y las ramas ventriculares.

**Haz de His:** se dividen en dos ramas; una rama derecha para el ventrículo derecho y una rama izquierda para el ventrículo izquierdo, desde donde el impulso eléctrico es distribuido a los ventrículos mediante una red de fibras que ocasionan la contracción ventricular llamadas Fibras de Purkinje. La contracción ventricular se refleja en el ECG mediante el complejo QRS (figura 4). Posteriormente, los ventrículos se relajan (onda T) del ECG. En ocasiones puede distinguirse una onda adicional (onda U) en el ECG.

### 1.1.3 Propiedades electrofisiológicas de las células cardíacas

Cada latido del corazón es impulsado por un potencial de acción que se origina en el interior del corazón y es conducido rápidamente a través de dicho órgano. El origen de impulso eléctrico se empieza en las células del miocardio, las cuales pueden ser excitadas eléctricamente, produciéndose un flujo continuo bidireccional de iones de potasio ( $K^+$ ), sodio ( $Na^+$ ), y calcio ( $Ca^{++}$ ) a través de su membrana, lo cual induce un potencial eléctrico variable en el interior y en el exterior. Dando paso a la contracción coordinada [1].

El potencial de acción cardíaco se divide en cinco fases dependiendo del nivel de las corrientes hará el interior de la célula de  $K^+$ ,  $Na^+$  y  $Ca^{++}$ , como muestra la figura 5.

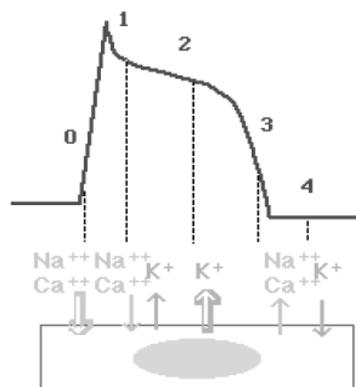


FIGURA 5. EL POTENCIAL ELÉCTRICO DE LAS CÉLULAS DEL MIOCARDIO, LAS FLECHAS CORRESPONDEN A LOS PRINCIPALES MOVIMIENTOS DE IONES A TRAVÉS DE LA MEMBRANA CELULAR [6].

- Fase 0: despolarización rápida, que tiene lugar por la apertura del canal rápido de  $\text{Na}^+$  que genera una corriente de  $\text{Na}^+$ , y más tarde de  $\text{Na}^+/\text{Ca}^{++}$ .
- Fase 1: repolarización transitoria, se genera por la salida rápida de la célula de iones  $\text{K}^+$ .
- Fase 2: meseta, se produce por el equilibrio entre la salida de  $\text{K}^+$  y la apertura de los canales de  $\text{Ca}^{++}$ .
- Fase 3: repolarización la membrana celular por la salida del  $\text{K}^+$ .
- Fase 4: equilibrio basal, es el intervalo desde que se completa la repolarización hasta que comienza el siguiente potencial de acción, (en la figura 5 se ve que sale  $\text{Na}^+$   $\text{Ca}^{++}$  y entra  $\text{K}^+$ ).

Estas variaciones de voltaje en el corazón son las que se detectan con el electrocardiograma.

## 1.2 Técnicas de diagnóstico en cardiología

Los métodos de diagnóstico en cardiología se pueden enumerar en dos grandes grupos:

- Métodos de diagnóstico invasivos: técnicas que permiten evaluar enfermedades cardíacas introduciendo cuerpos extraños de diagnóstico en el organismo.
- Métodos de diagnóstico no invasivos: son técnicas que no necesitan introducir ningún cuerpo extraño en el organismo. Se realiza con equipos externos, con o sin contacto con el paciente.

A continuación se presentan algunas técnicas de diagnóstico [7].

### 1.2.1 Técnicas invasivas

**Cateterismo cardíaco:** se basa en la introducción de catéteres en el interior de las cavidades del corazón con la finalidad de medir presiones en dichas cavidades, y la cantidad de sangre que es bombeada por el corazón. Es una de las pruebas invasivas más utilizadas para efectuar un diagnóstico cardíaco, debido a la información que proporciona, es muy útil desde el punto de vista médico para tratar adecuadamente al enfermo [8].

**Coronariografía:** en esta técnica se realiza el mismo procedimiento de insertar catéteres en el interior de las cavidades del corazón para poder visualizar las arterias coronarias mediante rayos X y de este modo poder diagnosticar ciertas enfermedades [9].

### 1.2.2 Técnicas no invasivas

Estas técnicas se caracterizan por usar equipos de medida que están en contacto con el paciente de forma superficial.

**Ultrasonografía cardíaca (Ecocardiografía):** es un examen que permite captar imágenes del movimiento del corazón mediante el uso de ultrasonidos lo cual aporta información sobre la forma, tamaño, fuerza del corazón, función, movimiento, funcionamiento de sus válvulas, el grosor de sus paredes, etc.

**Electrocardiograma (ECG):** es una prueba diagnóstica que registra la actividad eléctrica del corazón por medio de electrodos que son ubicados en sitios específicos del cuerpo [10]. Einthoven fue el primero en usar el término ECG, en un artículo en 1893 sobre los nuevos métodos de investigación clínica [6]. En la sección 1.3 se desarrolla detalladamente la ECG.

**Holter Electrocardiográfico:** es muy importante para determinar arritmias. Es una prueba que permite el registro de la actividad eléctrica del corazón de forma continua durante 24 horas.

**Holter de Presión:** el Holter de presión arterial es una medida que tiene gran importancia pues controla la presión arterial cada 15-30 minutos durante el día y noche [11].

**Tomografía Computada (TC):** en esta técnica los múltiples detectores del scanner permiten crear imágenes detalladas usando rayos X. Esta prueba permite ver el corazón, los pulmones, los grandes vasos y la aorta [12].

**Resonancia Magnética Nuclear (RMN):** permite obtener unas imágenes más detalladas del corazón con relación a la radiografía de tórax. Es útil para el estudio de las enfermedades valvulares, las pericárdicas y las miocardiopatías [13].

**Radiografía de Tórax (RxT):** es un test de diagnóstico por rayos X. Una radiografía de tórax produce imágenes que permiten observar la circulación pulmonar, el tamaño de las cavidades cardíacas, etc. [14].

**Ergometría:** se conoce también como test de esfuerzo y se usa con frecuencia en cardiología. Es una prueba basada en la realización de ejercicio físico en una bicicleta estática o tapiz rodante, mientras se monitoriza el ritmo del corazón y la presión arterial [15].

**Grabador de Eventos:** se trata de un equipo portátil pequeño que el paciente debe llevar para registrar mediante electrodos su ECG durante un largo período de tiempo [16].

**Telemetría:** el registro del ECG se realiza a distancia mediante unos radiotransmisores.

**Vectocardiografía:** es un método complementario al de la electrocardiografía. En este test se distinguen tres planos en los cuales se proyectan vectores [17].

**Fonocardiografía:** es el registro de señales de audiofrecuencia (ruidos y murmullos cardíacos) [18].

**Mecanocardiografía:** es una técnica que registra el gráfico de pulsaciones de baja frecuencia producidas por el corazón [19].

## 1.3 Interpretación de las ondas componentes del ECG

### 1.3.1 Electrocardiografía

El ECG representa gráficamente la actividad eléctrica del corazón mediante el uso de una serie de electrodos que son colocados en la superficie de la piel.

### 1.3.2 Sistema de derivaciones electrocardiográficas

Es posible obtener 12 derivaciones desde ángulos diferentes en dos planos perpendiculares de observación. Las derivaciones se registran colocando 10 electrodos en la superficie del cuerpo. Seis de los electrodos se colocan en el pecho, mientras que los restantes 4 electrodos se colocan en cada una de las extremidades del paciente. Las derivaciones utilizan diferentes combinaciones de los electrodos, con lo cual cada uno registra información de una parte concreta del corazón [20].

Las derivaciones se dividen en dos grupos: Derivaciones del plano frontal y derivaciones del plano horizontal.

#### 1.3.2.1 Derivaciones del plano frontal

Las derivaciones del plano frontal están constituidas por 6 derivaciones: 3 derivaciones bipolares de Einthoven (DI, DII y DIII) [21], y 3 derivaciones unipolares aumentadas de Goldberger (aVR, aVL y aVF) [6].

**Derivaciones bipolares estándar:**

Las derivaciones cardíacas clásicas de Einthoven utilizan 3 electrodos de los cuales dos de ellos son colocados uno en cada brazo mientras que el tercero es colocado en la pierna izquierda, formando un triángulo que se conoce como el triángulo de Einthoven. Posteriormente, se registran los potenciales eléctricos entre dos electrodos ubicados en extremidades diferentes en el plano frontal motivo por el cual se les conocen como derivaciones bipolares, ver la figura 6.

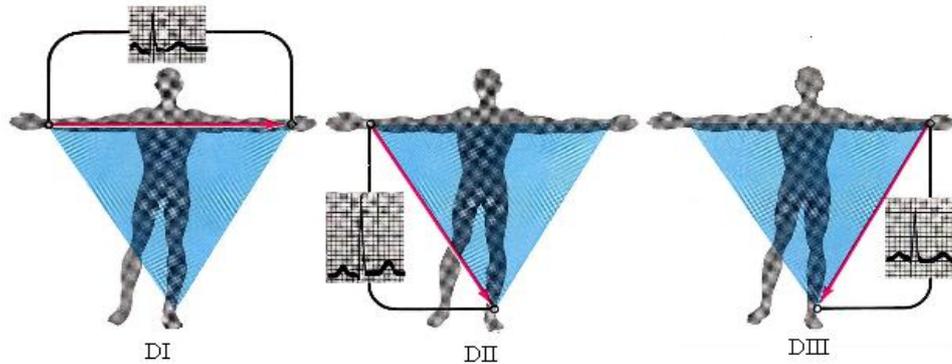


FIGURA 6. DERIVACIONES DE EXTREMIDADES EINTHOVEN (ESTÁNDAR)<sup>1</sup>.

Siendo VL (*vector left*, por sus siglas en inglés) el potencial en el brazo izquierdo, VR (*vector right*, por sus siglas en inglés) el potencial de brazo derecho y VF (*vector foot*, por sus siglas en inglés) el potencial en la pierna izquierda, las tres derivaciones bipolares de Einthoven son:

Derivación I (DI): mide la diferencia de potencial entre el brazo derecho ( $V_R$ ) y el brazo izquierdo ( $V_L$ ), como se indica en (1).

$$DI = V_L - V_R \quad (1)$$

Derivación II (DII): mide la diferencia de potencial entre el brazo derecho ( $V_R$ ) y el pie izquierdo ( $V_F$ ), como se indica en (2).

$$DII = V_F - V_R \quad (2)$$

Derivación III (DIII): mide la diferencia de potencial entre el brazo izquierdo ( $V_L$ ) y el pie izquierdo ( $V_F$ ), como se indica en (3).

<sup>1</sup>“<http://www.electrocardiografia.es/>.”

$$DIII = V_F - V_L \quad (3)$$

### Derivaciones unipolares aumentadas de Goldberger:

Las derivaciones unipolares aumentadas de Goldberger fueron inicialmente ideadas por Frank Wilson pero Goldberger las modificó aumentando la onda hasta en un 50% y de aquí que estas derivaciones se llamen aVR, aVL, aVF.

En la figura 7 se observan las 3 derivaciones de Goldberger (aVR, aVL y aVF). La derivación aVR (*augmented vector right*, por sus siglas en inglés) posee el electrodo positivo ubicado en el brazo derecho siendo el electrodo negativo es una combinación de los electrodos del brazo izquierdo y de la pierna izquierda, como se desarrolla en (4).

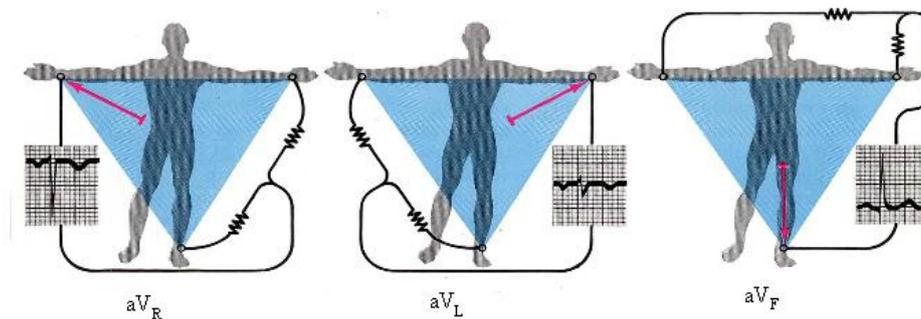


FIGURA 7. DERIVACIONES DE EXTREMIDADES AUMENTADAS DE GOLDBERGER<sup>1</sup>.

La derivación aVL (*augmented vector left*, por sus siglas en inglés) posee el electrodo positivo colocado en el brazo izquierdo entretanto que el electrodo negativo es una combinación de los electrodos del brazo derecho y la pierna izquierda, como se indica en (4).

$$\begin{cases} aV_R = V_R - \frac{V_L + V_F}{2} \\ aV_L = V_L - \frac{V_R + V_F}{2} \\ aV_F = V_F - \frac{V_L + V_R}{2} \end{cases} \quad (4)$$

La derivación aVF (*augmented vector foot*, por sus siglas en inglés) tiene el electrodo positivo ubicado en la pierna izquierda mientras que el electrodo negativo es una combinación de los electrodos del brazo derecho y el brazo izquierdo, como se indica en (4).

<sup>1</sup> “<http://www.electrocardiografia.es/>.”

### 1.3.2.2 Derivaciones precordiales o derivaciones del plano horizontal

Wilson introdujo las derivaciones del plano horizontal V1, V2, V3, V4, V5, y V6 con el fin de medir el potencial cerca del corazón. Estas seis derivaciones encuentran en el lado izquierdo del pecho (mayor voltaje). Todas ellas se cruzan en el nodo AV, como muestra la figura 8.

El potencial es registrado desde un electrodo (polo positivo) que es colocado en el pecho y de otro electrodo de referencia (polo negativo) conectado al terminal central de Wilson, compuesto por los varios de los electrodos  $V_F + V_L + V_R$ .

V1: Esta derivación ECG registra los potenciales de las aurículas, también de parte del tabique y de la pared anterior del ventrículo derecho.

V2: El electrodo de esta derivación precordial, se coloca por encima de la pared ventricular derecha.

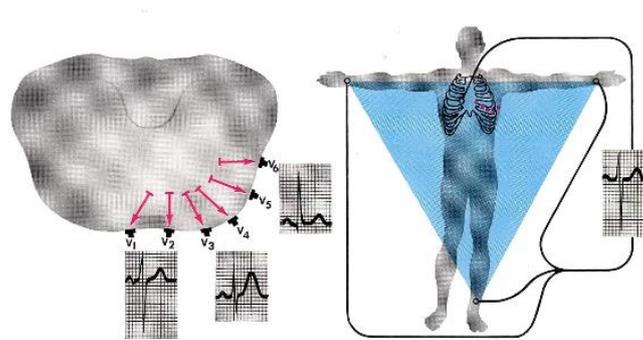


FIGURA 8. DERIVACIONES PRECORDIALES DEL PLANO HORIZONTAL<sup>1</sup>.

V3: Al estar el electrodo sobre el septo interventricular esta derivación es una derivación transicional entre los potenciales izquierdos y derechos del ECG.

V4: El electrodo de esta derivación se ubica sobre el ápex del ventrículo izquierdo.

V5 y V6: Estas derivaciones del ECG están situadas sobre el miocardio del ventrículo izquierdo.

## 1.3.3 Registro de la actividad

### 1.3.3.1 Ondas, segmentos e intervalos del ECG

Durante las fases de despolarización y repolarización, se registran en el ECG normal una serie de ondas: la onda P, el complejo QRS, la onda T y la onda U, como muestra la figura 9.

<sup>1</sup> “<http://www.electrocardiografia.es/>.”

Entre las ondas se encuentran lo que se conocen como segmentos, P-R y S-T. Son características del ECG los denominados intervalos que incluyen ondas y segmentos: P-R, QRS; Q-T y S-T [6].

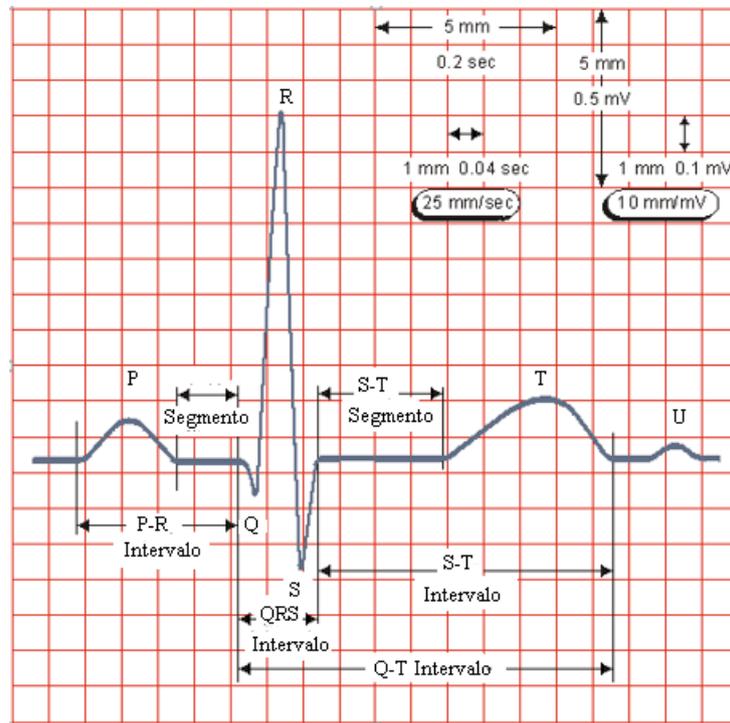


FIGURA 9. MODELO IDEAL DEL CICLO CARDIACO<sup>1</sup>.

**La onda P:** es una pequeña onda que corresponde a la despolarización de las aurículas (contracción o sístole auricular), la anchura de una onda P determina el tiempo que demora un impulso en pasar del nodo SA al nodo AV con una duración máxima de 0,10s.

**Complejo QRS:** este complejo corresponde a la corriente eléctrica que causa la contracción de los ventrículos (despolarización ventricular). Es el componente más característico del ECG. Se inicia con una onda descendente, continúa con una onda rápida triangular ascendente y finaliza con una pequeña deflexión. Está constituido por la sucesión de las ondas Q, R, S. Duración entre 60-100ms.

**Onda Q:** representa la deflexión negativa inicial resultante de la despolarización ventricular, que precede a la onda R, con una duración habitual de 40ms.

<sup>1</sup> “<http://www.electrocardiografia.es/>.”

**Onda R:** es la primera deflexión positiva que aparece durante la despolarización ventricular.

**Onda S:** es la segunda deflexión negativa que se obtiene durante la despolarización ventricular la cual en ocasiones puede no visualizarse.

**Onda T:** es la onda positiva ascendente y suave que aparece después del complejo QRS y representa la repolarización ventricular (relajación o diástole ventricular). Tiene una duración de aproximadamente 200ms o menos.

**Onda U:** Esta onda no es constante, tiene una dirección positiva, aunque puede ser negativa, Su origen no está bien definido y su duración es de 160-240ms.

**Segmento S-T:** representa el intervalo entre el final del complejo QRS y el inicio de la onda T. Este segmento se asocia con el proceso de recuperación o repolarización ventricular. Duración típica: 240ms.

**Segmento P-R:** corresponde a la línea isoelectrica definida desde el comienzo de la onda P hasta la deflexión inicial del complejo QRS. La duración normal de este segmento está entre los 0,12 y los 0,21s.

**Intervalo R-R:** equivale a la distancia entre dos ondas R sucesivas, con una duración típica entre 600-1000ms.

**Intervalo Q-T:** es la distancia desde el inicio de la onda Q hasta el final de la onda T. Representa el principio de la despolarización ventricular hasta el final de la repolarización ventricular. El intervalo Q-T depende la frecuencia cardíaca. Duración típica: 300-400ms

**Intervalo P-P:** es la distancia entre dos ondas P sucesivas; sí el ritmo es regular, debe medir lo mismo que el intervalo R-R.

**Intervalo P-R:** mide la distancia desde el comienzo de la onda P hasta el inicio del complejo QRS. Determina el tiempo en el que el impulso eléctrico está viajando del nodo SA, (a través del nodo AV) hacia los ventrículos. Duración típica: 120-200ms.

### 1.3.3.2 Frecuencia cardiaca

La frecuencia cardiaca es la rapidez con la que se expande el impulso eléctrico del corazón, se considerada normal si esta entre 60 y 100 latidos por minuto, y para calcularla se toma en cuenta el tiempo que existe entre dos ondas R sucesivas.

*En este capítulo se presenta una breve introducción sobre las características de las arritmias ventriculares malignas especialmente la fibrilación ventricular, así como la justificación fisiológica de la forma de onda relacionada con cada una de ellas. Además, se describe cómo usar los desfibriladores automáticos.*

## Capítulo 2. Ritmos cardíacos

### 2.1 Ritmo sinusal normal (Ritmo Normal)

Se define como ritmo normal del corazón aquel que se produce en el nódulo sinusal pasando por el nodo AV y que posteriormente lleva la conducción a los ventrículos por el Haz de His y las ramas siguientes (ver sección 1.1.2), como ejemplo, observar la figura 10.

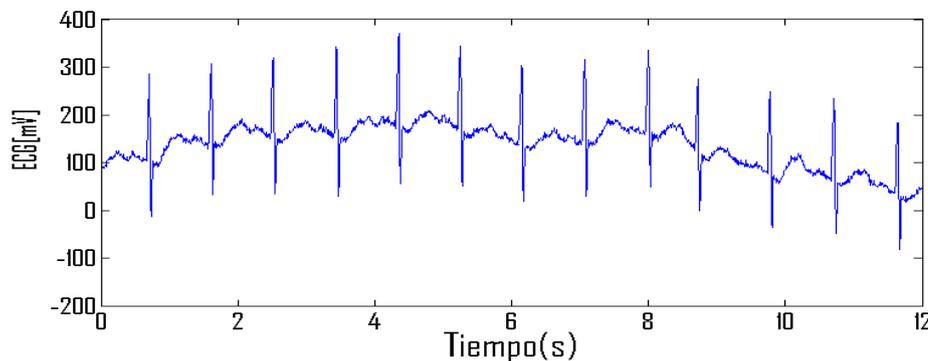


FIGURA 10. SEÑAL ECG DE RITMO SINUSAL NORMAL (RITMO)<sup>1</sup>.

El ritmo es considerado sinusal normal cuando:

- Todas las ondas P van seguidas de complejos QRS.
- El ritmo es regular.
- La frecuencia habitual en reposo es de entre 60 y 100 latidos/minuto (lpm).
- La onda P es negativa en aVR y positiva en I, II, aVF, V4, V5 y V6.
- Los intervalos P-R tienen tiempos menores de 0.20s y son constantes.
- Las señales Ritmo Normal tienen en común que son muy regulares en el ritmo (intervalo P-P regular).

<sup>1</sup>“<http://physionet.org>.”

Dentro del Ritmo Normal se observan variaciones en la morfología del complejo QRS:

Existen algunas señales de las ondas P y T que tienen valores muy pequeños en las que no es fácil distinguirlas, otras tienen la onda R mucho mayor, etc.

## 2.2 Arritmias cardíacas

Las arritmias cardíacas se definen como la irregularidad en el ritmo natural del corazón. Éstas se refieren a cualquier cambio de lugar en la generación del pulso eléctrico del corazón. Pueden registrarse de manera continua o esporádica y se dividen en dos tipos: supraventriculares y ventriculares.

Las arritmias supraventriculares se producen generalmente en las aurículas, mientras que las arritmias ventriculares se producen en los ventrículos.

Las arritmias también se definen según la velocidad de los latidos:

- La bradicardia: es la disminución de la frecuencia cardíaca por debajo de 60 lpm.
- Taquicardia: es el aumento de la frecuencia cardíaca por encima de 100 lpm.

### Clasificación de las principales arritmias:

#### Arritmias supraventriculares:

- Taquicardia sinusal: arritmia originada en el nodo sinusal con frecuencia cardíaca > latidos 100 por minutos.
- Bradicardia sinusal: arritmia originada en el nodo sinusal con frecuencia cardíaca < 60 latidos por minutos.
- Arritmia sinusal respiratorio: son alteraciones sinusales de la frecuencia, es más frecuente en jóvenes. Es de origen repertorio, es fisiológica por lo que no necesita tratamiento.
- Taquicardia supraventriculares: son latidos sostenidos con frecuencia superior a 100 lpm, que se originan en las aurículas o en el nodo aurículo ventricular, entre ellas tenemos:
  - Flutter auricular: se producen estímulos en la aurícula a frecuencias que varían entre 240 y 340 lpm.

- Fibrilación auricular es la más frecuente, se produce por una activación desordenada del tejido auricular por múltiples focos. La activación anarquica origina una frecuencia de 400-700 por minuto.

### **Arritmias ventriculares:**

- Extrasístoles ventriculares: es una contracción ventricular prematura con un complejo QRS anormal.
- Taquicardia ventricular (TV): son ritmos rápidos originados en cualquier parte de los ventrículos, que electrocardiográficamente originan QRS anchos. La presencia de 3 o más extrasístoles seguidas ya se consideran una TV.
- Flutter y fibrilación ventricular (FV). Arritmia caracterizada por ondas muy rápidas y anormales.

Un estudio detallado de los diferentes tipos de arritmias puede consultarse en [22]. Las patologías en las que estamos particularmente interesados en este trabajo son las arritmias ventriculares.

## **2.2.1 Arritmias ventriculares**

Las arritmias ventriculares son causantes de una gran morbilidad y mortalidad, y continúan siendo una complicación grave de las cardiopatías, con riesgo de muerte súbita. Se denomina arritmia ventricular a un trastorno del ritmo cardíaco originado en el músculo ventrículo, por debajo del nódulo auriculoventricular y del Haz de His, pudiendo los latidos ser demasiado rápidos o lentos o tener un patrón irregular.

Las arritmias ventriculares pueden ser: Extrasístole Ventricular, Taquicardia Ventricular, Flutter y Fibrilación Ventricular.

### **2.2.1.1 Extrasístoles ventriculares**

Se conoce como un latido adicional producido por una activación eléctrica anómala que se origina en los ventrículos antes de un latido cardíaco normal. La clasificación según la morfología de los complejos ventriculares prematuros pueden ser monomórficos (una sola morfología) o polimórficos (varias morfologías). Por otro lado, si tienen más de tres latidos consecutivos se les llama taquicardia ventricular, como muestra la figura 11.

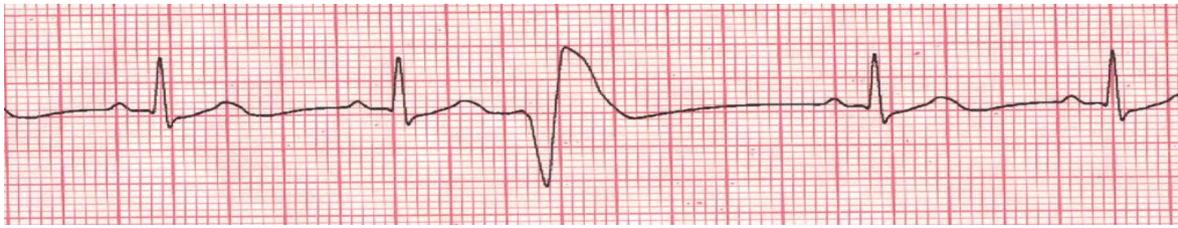


FIGURA 11. EXTRASÍSTOLES VENTRICULARES<sup>1</sup>.

### 2.2.1.2 Taquicardia ventricular

La taquicardia ventricular (TV) se produce cuando el ritmo cardiaco no está marcado por el nódulo SA, sino por una zona del ventrículo que comienza a enviar señales eléctricas rítmicas a mayor frecuencia<sup>2</sup>.

En estos casos el corazón tiene poco tiempo para llenarse entre dos latidos consecutivos y la cantidad de sangre que envía al resto del cuerpo es inferior a la que enviaría en una situación normal. Esta falta de sangre en el cerebro produce lipotimias.

La taquicardia ventricular es muy peligrosa y su identificación puede permitir el diagnóstico oportuno y disminuir el riesgo de muerte súbita en el paciente. En este grupo se observa una gran diversidad en las señales. Unas señales tienen un patrón muy regular y claro (TV monomórfica) que se aprecia en la figura 12, mientras que otras son muy irregulares y la forma de sus ondas se parece mucho a la de la fibrilación ventricular (TV polimorfa).

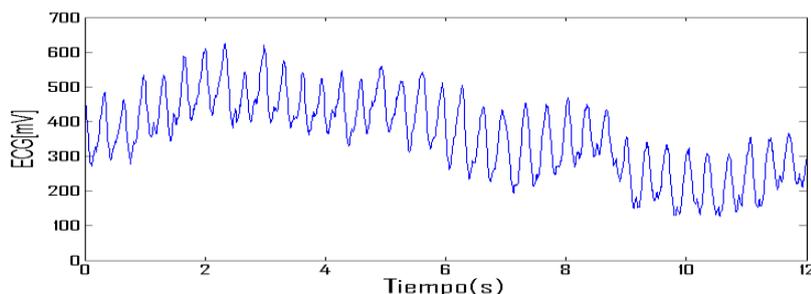


FIGURA 12. SEÑAL ECG CON EPISODIOS DE TAQUICARDIA VENTRICULAR<sup>3</sup>.

**TV monomórfica:** Características electrocardiográficas de una taquicardia ventricular:

- Sucesión de más de 3 latidos ventriculares seguidos.

<sup>1</sup> “<http://medlibes.com/entry/premature-ventricular-contractions.>”

<sup>2</sup> “[http://www.practicalclinicalskills.com/ekg.aspx,](http://www.practicalclinicalskills.com/ekg.aspx)”

<sup>3</sup> “[http://physionet.org.,](http://physionet.org.)”

- Frecuencia cardíaca entre 100-250 latidos por minuto.
- Onda P: es común que esté oculta por el complejo QRS.
- Complejo QRS: ancho (superior a 0.12s) y anómalo, con ondas T en dirección contraria.

**TV polimorfa:** además de la taquicardia ventricular monomórfica, existe otro tipo de taquicardia ventricular conocida como taquicardia ventricular polimorfa. Esta presenta complejos QRS que cambian constantemente, siendo frecuentemente observada más en hombres y asociándose más a factores genéticos que atacan a los canales que conducen el flujo de iones de la despolarización. Esta taquicardia provoca muerte súbita y síncope.

Estos dos tipos de taquicardias son muy particulares ya que son fáciles de confundir con la fibrilación ventricular, puesto que ambas taquicardias constan de señales altamente irregulares que suelen degenerar en fibrilación ventricular y se debe aplicar un tratamiento, aplicando el choque eléctrico controlado a un paciente con el fin de reinicio de la actividad eléctrica cardíaca normal.

### 2.2.1.3 Flutter y fibrilación ventricular

#### Flutter ventricular

Flutter ventricular (FL) es una arritmia ventricular que se desarrolla hasta convertirse en una fibrilación ventricular (FV). Consiste en una onda oscilante continua, en la que no se pueden distinguir ni los complejos QRS ni las ondas T. Es muy rápida, con una frecuencia mayor de 200 lpm, ver la figura 13.

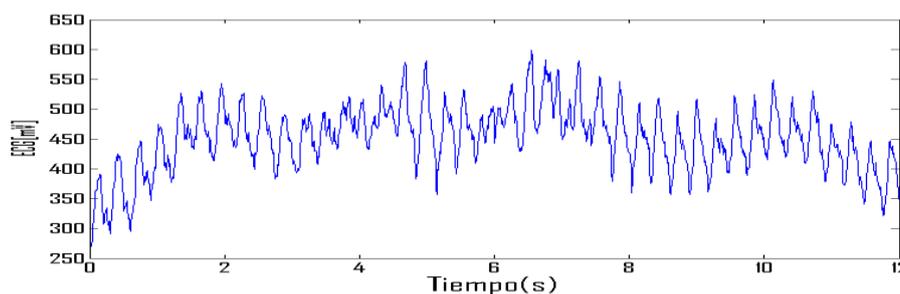


FIGURA 13 SEÑAL ECG CON EPISODIOS DE FLUTTER VENTRICULAR<sup>1</sup>.

<sup>1</sup> “<http://physionet.org>,”

Es un estado de emergencia eléctrico intermedio entre la taquicardia ventricular y la fibrilación ventricular y su tratamiento es similar a la fibrilación ventricular.

### Fibrilación ventricular

La fibrilación ventricular fue expuesta por primera vez por Erichsen en 1842 [23]. En 1914, Garrey publicó el primer estudio sistemático de la relación existente entre la FV y el tamaño del corazón [24]. En 1923, DeBoer demostró que una sola descarga eléctrica aplicada en la fase final de la sístole en el corazón de la rana desencadenaba la fibrilación de aquella cámara [25].

En la fibrilación ventricular algunos impulsos que se originan al mismo tiempo en diferentes lugares de los ventrículos estimulan al corazón y creando latidos muy rápidos y desordenados, que pueden superar los 300 lpm. Esto le confiere al ECG una imagen ondulatoria de amplitud y contornos variables. En esta imagen no se distinguen los complejos QRS, el segmento ST, ni las ondas T como muestra la figura 14, con lo cual no se produce llenado ni vaciado de las cavidades, impidiendo una circulación adecuada de la sangre. Si no se logra poner en marcha el corazón a tiempo, en los minutos posteriores ocurrirá la muerte súbita cardíaca [26].

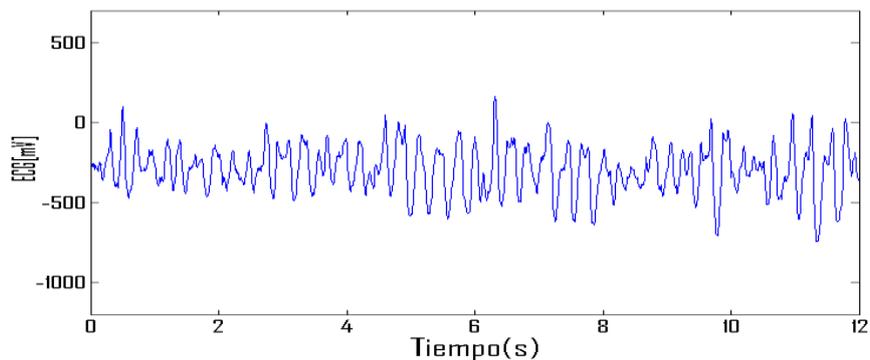


FIGURA 14. SEÑAL ECG CON EPISODIOS DE FIBRILACIÓN VENTRICULAR<sup>1</sup>.

Requiere terapia inmediata mediante la desfibrilación con la máxima energía necesaria ver sección 2.3 de este capítulo.

La fibrilación ventricular tiene las siguientes características<sup>2</sup>:

- Frecuencia: rápida, descoordinada e ineficaz con valores > 300 lpm.

<sup>1</sup> “<http://physionet.org>,”

<sup>2</sup> “<http://www.practicalclinicalskills.com/ekg.aspx>,”

- Onda P: no se identifica.
- Complejo QRS: ondulaciones rápidas e irregulares. No se visualizan complejos QRS, sin patrón específico.
- Conducción: la conducción es desorganizada dentro de los ventrículos, los pulsos se originan en cualquier momento.
- Ritmo: es muy irregular y sin un patrón específico.

## 2.3 Desfibrilación y cardioversión

### 2.3.1 Tratamiento de FV

Como se ha comentado en la sección 2.2.1 de este capítulo, la muerte cardíaca súbita se define clínicamente como una muerte cardíaca inesperada que ocurre dentro de un tiempo muy corto, por lo general un tiempo de menos de una hora después de la aparición de los primeros síntomas. Sus principales causas son la taquicardia y la fibrilación ventricular. Ambas arritmias ventriculares causan una incapacidad del corazón para bombear la sangre, lo que da como resultado un ataque cardíaco. Puede ocurrir en cualquier instante en que los órganos del cuerpo no reciban suficiente oxígeno, por lo tanto, la FV es una emergencia médica y debe tratarse inmediatamente para salvar la vida de la persona.

#### Las técnicas de detección de FV

Se han realizado múltiples técnicas para mejorar la detección de FV la discriminación entre FV y otras arritmias como la TV. Para ello, como referencia se han usado:

- Técnicas en el dominio del tiempo y de la frecuencia.
- Representación tiempo-frecuencia.
- Redes neuronales y wavelet, etc.

Para información más detallada ver los capítulos 3 y 4.

El objetivo final de los algoritmos desarrollados es lograr un diagnóstico útil y preciso de la patología cardíaca. Para recuperar inmediatamente el latido cardíaco y llevarlo a un ritmo normal se puede emplear:

- Un dispositivo de desfibrilación externo automático o cardioversión. El mismo consiste en proveer una descarga eléctrica para facilitar el reinicio de la actividad eléctrica cardíaca normal [27].
- En otros casos se aplican tratamientos preventivos de arritmias tales como cambio de estilo de vida, evitar el consumo de alcohol, dejar de fumar, reducir la cafeína, disminución del estrés y aumento de los niveles de actividad física e incluso la administración de fármacos para prevenir la aparición de taquiarritmia.

## 2.3.2 Dispositivo de desfibrilación

Publicaciones recientes han mostrado una reducción de la mortalidad en pacientes con arritmias ventriculares malignas usando desfibriladores implantables. En España actualmente se han colocado estos desfibriladores en la mayoría de los aeropuertos así como en grandes complejos comerciales, zonas comunes de los hospitales, centros deportivos, estaciones de metro o ferrocarril, etc.

Existen dos tipos de desfibriladores: los desfibriladores automáticos externos y los desfibriladores automáticos implantables.

### 2.3.2.1 Desfibriladores externos

En años recientes se han diseñado modelos avanzados de desfibriladores llamados desfibriladores externos automáticos, que consisten en la aplicación de una descarga eléctrica que atraviesa el tórax del paciente usando almohadillas externas o palas.

#### **Desfibrilador Externo Manual (DEM)**

Es un aparato que consta de un desfibrilador, un monitor de electrocardiografía y una cardioversión. Es uno de los más usados, y para su uso es necesario personal médico especialmente entrenado sobre el manejo de estas máquinas [28].

#### **Desfibrilador Externo Semi-automático (DESA)**

Es un instrumento que puede ser usado por personas que no sean personal sanitario pero sí entrenadas en la misma, debido a que se requiere más participación del operador.

Este tipo de desfibrilador está compuesto de un analizador de electrocardiogramas que detecta la fibrilación ventricular en pocos segundos mediante una alarma, con lo cual el desfibrilador descarga un fuerte choque eléctrico entre los parches situados en el pecho del paciente de manera automática [29].

### **Desfibrilador Externo Automático (DEA)**

Es un aparato electrónico portátil que diagnostica y trata el paro cardiorrespiratorio cuando es debido a la fibrilación ventricular o a una taquicardia ventricular. La desfibrilación consiste en generar un impulso de corriente continua al corazón, para ayudar a que éste pueda retomar su ritmo eléctrico normal. Este equipo es totalmente automatizado, sin intervención del operador y está diseñado para ser utilizado sin mayor preparación ni conocimiento previo [28].

#### **2.3.2.2 Desfibriladores interno automático**

**Desfibrilador Interno Automático (DIA)** es aplicado a aquellos pacientes que tengan riesgo de fibrilaciones ventriculares continuas. Consiste en un dispositivo interno, está situado junto al corazón detectando continuamente el corazón y si encuentra una FV descarga un impulso eléctrico usando unos electrodos implantados en el ápex y en la base del corazón [30].

#### **2.3.3 Las diferencias entre tratamiento de FV y TV**

El tratamiento de la FV se realiza mediante la desfibrilación. En esta se descarga una corriente eléctrica de un alto voltaje directa sobre el tórax o directamente a través del ventrículo, logrando la recuperación de la actividad eléctrica normal. Se debe tener en cuenta que siempre se debe realizar de forma urgente.

Por otro lado las arritmias sostenidas como la taquicardia ventricular, el flutter auricular, la fibrilación auricular, etc.; pueden provocar inestabilidad hemodinámica y fallo cardíaco. Para éstas el tratamiento utilizado es la cardioversión; en la cual se aplica una descarga eléctrica de menor voltaje y sincronizada con el complejo QRS, ya sea sobre el tórax o directamente a través del ventrículo, con el fin de recuperar el ritmo normal [31].

*Inicialmente, se presenta una revisión bibliográfica de los métodos y técnicas que existen en la actualidad, así como sus aplicaciones a las señales ECG para su pre-procesamiento. Se presenta una breve introducción sobre las diferentes bases de datos de la señal ECG. Se describen los datos usados en este trabajo. Además, se describen las técnicas de filtros y la metodología del procesamiento de la señal ECG usadas en el presente trabajo de tesis. Luego se describen las limitaciones en el análisis de señales no estacionarias, y las expresiones matemáticas correspondientes a las principales distribuciones de tiempo-frecuencia. Finalmente, se describen los métodos relacionados con las técnicas desarrolladas para el diagnóstico de la señal ECG.*

## **Capítulo 3. Procesamiento de la señal electrocardiográfica (ECG)**

### **3.1 Introducción**

La muerte súbita se define clínicamente como la muerte inesperada de una persona aparentemente sana, debido generalmente a causas cardiacas que puede ocurrir en cuestión de minutos tras los primeros síntomas. Muchas de las víctimas del paro cardíaco súbito pueden sobrevivir si los testigos actúan de forma inmediata después de la aparición de los primeros síntomas. Se ha demostrado que la desfibrilación es el único tratamiento efectivo contra un paro cardíaco súbito causado por una FV [32]. En la desfibrilación se impulsa una corriente eléctrica a través del corazón aplicándola mediante unos electrodos que se situaran en el tórax de la víctima. La evidencia científica indica que la desfibrilación temprana es determinante en la recuperación de la víctima. En el caso de la TV los posibles tratamientos serían el uso de medicamentos y en otros casos se usa la cardioversión que es la aplicación de una descarga eléctrica de bajo voltaje, ya sea sobre el tórax o directamente a través del ventrículo, con el fin de recuperar el ritmo alternativo.

El éxito de la desfibrilación ventricular es inversamente proporcional al intervalo de tiempo desde el comienzo del episodio de FV hasta la aplicación de la descarga. Aparecen muchas dificultades a la hora de diagnosticar la FV, por una parte están las características intrínsecas de la FV (falta de organización, irregularidad, etc.), y por otra, la diferenciación entre FV y TV

dado que el diagnóstico erróneo de la TV como FV en un paciente puede ocasionarle graves lesiones ya que la aplicación de una terapia contra FV (desfibrilación) a un paciente que sufre TV puede causarle una FV. Por lo tanto, un método de detección eficaz de FV y discriminación de otras arritmias similares como la TV tiene importancia en la investigación clínica.

Muchos estudios experimentales y clínicos describen que los pacientes que tienen una historia de riesgo cardiaco requieren de métodos invasivos para detección de patología cardiaca y requieren cirugía. Sin embargo, muchos de los casos de FV aparecen en pacientes no diagnosticados previamente.

El ECG es la única técnica superficial de detección disponible, por lo tanto el ECG de monitorización a menudo se logra mediante el uso de equipos de emergencia externos como DEA.

En la señal ECG, como en la mayoría de la señales biomédicas, la presencia de ruido es un problema difícilmente evitable ya que no se puede separar el sistema cardiovascular de otros sistemas cercanos tanto fisiológicos como de adquisición [33]. La reducción del ruido en el ECG ha sido uno de los temas más estudiados en la bibliografía. Son muy diferentes las maneras de afrontar este problema y no existe una única estrategia de aplicación universal a todas las fuentes de ruido. En diversos trabajos se han usado diferentes filtros para la reducción de las variaciones de la línea base y de otras perturbaciones provenientes del exterior.

Se han desarrollado múltiples técnicas como la transformada de Hilbert [34], transformada de Fourier [35], transformada wavelet, otras técnicas de procesamiento de señal y las representaciones de tiempo-frecuencia [36], que sirven para poder obtener adecuadamente la máxima información de un ECG y son usadas como base para el diagnóstico automático de episodios de FV. Estas técnicas consisten en extraer características en el dominio del tiempo o en el dominio de la frecuencia. Algunas de estas técnicas comparten un aspecto común: combinan información temporal y espectral en la misma representación, lo cual es muy importante en las señales no estacionarias como las del ECG, especialmente cuando aparecen patologías irregulares como en FV.

En general, las técnicas de detección emplean típicamente parámetros obtenidos de la fase de pre-procesamiento de la señal para alimentar la entrada de un algoritmo de clasificación, esto se traduce en una pérdida de información de dicha señal. Esta información perdida puede ser

clave para discriminar adecuadamente entre distintas patologías como la FV y la TV. Por lo tanto el desarrollo e implementación de un algoritmo que permita discriminar con mayor precisión entre las diversas condiciones cardiacas es fundamental. Esta necesidad de desarrollar un algoritmo más preciso en la detección de estas patologías ha marcado el punto de partida de este trabajo de tesis.

La propuesta de este estudio es desarrollar un sistema de detección de la FV y su discriminación con TV basado en el análisis de tiempo-frecuencia del ECG, su conversión en imagen y su ingreso al clasificador sin necesidad de extracción de parámetros adicionales. Este análisis contiene todos los datos necesarios, tanto temporales como espectrales de la señal ECG que permite representar correctamente señales no estacionarias, por consiguiente, la hipótesis es que este método puede eliminar la pérdida de información discriminatoria producida por la extracción de parámetros.

## 3.2 Materiales

### 3.2.1 Base de datos de señales electrocardiográficas de Physiobank

Contiene las siguientes bases de datos de señales electrocardiográficas [37] entre ellas:

AHA DB: *The American Heart Association Database for Evaluation of Ventricular Arrhythmia Detectors.*

MIT-BIH DB: *The Massachusetts Institute of Technology-Beth Israel Hospital Arrhythmia Database.*

ESC DB: *The European Society of Cardiology ST-T Database.*

NST DB: *The Noise Stress Test Database.*

El MIT-BIH es una de las principales fuentes de señales ECG a nivel mundial. En esta base de datos se han incluido señales representativas de un conjunto muy amplio de patologías, además de ficheros con etiquetas realizados por expertos con el fin de servir de patrón para evaluar algoritmos aplicados a la señal electrocardiográfica. El uso de la base de datos del MIT-BIH permite el acceso a un conjunto de señales importante y suficientemente amplio como para realizar pruebas representativas.

Con este objetivo se va a utilizar como fuente de señales electrocardiográficas las bases de datos ofrecidas en la web de PhysioNet que incluye los datos de MIT-BIH.

### 3.2.2 Descripción de la base de datos

Los registros de las señales ECG se han tomado de las bases de datos estándar del MIT-BIH *Malignant Ventricular Arrhythmia Database*<sup>1</sup> y AHA (2000 series)<sup>2</sup>, generándose a partir de ellos tanto el conjunto de entrenamiento como el de prueba para los algoritmos de clasificación empleados. En total, se han empleado 24 registros de monitorización continua (22 registros de MIT-BIH más dos adicionales de la base de datos AHA), con frecuencia de muestreo de 125 Hz.

Todos los registros disponen de episodios cardiacos ya etiquetados, lo que permite la comparación con otros algoritmos que usen estas bases de datos como datos de prueba. Los registros AHA tienen como objetivo aumentar el número de episodios de Taquicardia Ventricular (TV) para mejorar el equilibrio entre el tiempo registrado de TV y los episodios de FV. Luego con los episodios etiquetados, fueron creados cuatro grupos (clases) de señales: ECG con existencia de fibrilación ventricular asignados a la clase 'FV' que son todos los tramos de registros en los que se ha producido fibrilación ventricular y flutter ventricular; taquicardia ventricular asignados a la clase 'TV' y que en muchos casos aparecen como una etapa previa a la FV (en ocasiones, algunos tramos de TV presentan morfologías similares a la FV); ritmos normales asignados a la clase 'Normal' que constituyen los tramos etiquetados como ritmo sinusal normal y finalmente el resto tipos de señales no etiquetados como ninguna de las clases anteriores (otras arritmias, ruido, etc.) que también han sido considerados y asignados a la clase 'Otros'.

En total, se generaron 20040s para todos los registros de señal ECG, 3600s correspondieron a la clase 'FV', 1380s a 'TV', 10860s a 'Normal' y 4200s a 'Otros'.

A partir de dichos registros se construyó un conjunto de entrenamiento y otro de prueba, (ver los capítulos 4 y 5).

---

<sup>1</sup> <http://physionet.org>.

<sup>2</sup> <http://ecri.org> (American Heart Association ECG Database).

### 3.3 Procesado de la señal ECG

Si buscamos que un clasificador obtenga un resultado satisfactorio de detección de la FV y su discriminación con TV, es necesario que los datos que se le proporcionen como entrada en dicho clasificador estén debidamente tratados. Por ello, tanto en la señal temporal de ECG como en su RTF se realizan distintas etapas de acondicionamiento. La figura 15 muestra el esquema general de la metodología seguida durante todo el proceso, desde la lectura de los registros de la base de datos hasta el resultado obtenido por el clasificador.

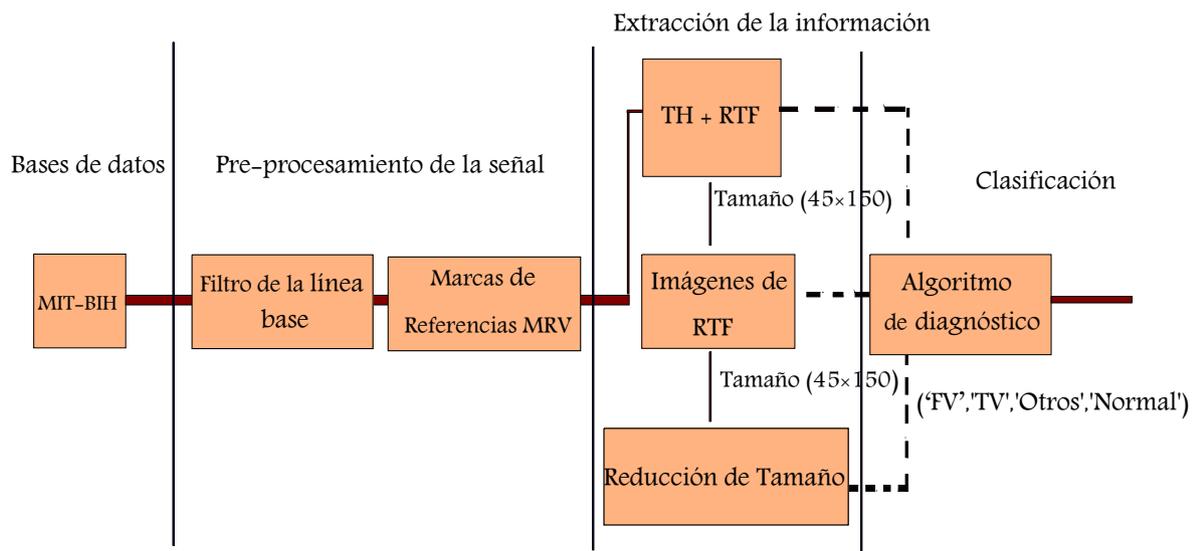


FIGURA 15. METODOLÓGICA GENERAL SEGUIDA EN ESTE TRABAJO.

En esta investigación la metodología desarrollada se compone de tres etapas fundamentales:

**Primera etapa:** algoritmo de filtrado, con el fin de reducir la línea base que afecta al ECG. Una vez filtrado, obtienen las Marcas de Referencias de las Ventanas (MRV) de la señal ECG mediante el algoritmo que fue desarrollado, donde cada MRV indica el comienzo de una Ventana de tiempo ( $V_t$ ) de la señal ECG.

**Segunda etapa:** Se refiere a la implementación de TH a cada ventana  $V_t$  obtenidas en la primera etapa, después se calcula la matriz de su RTF y la IRTF, para luego reducir la dimensionalidad de la matriz IRTF usando varias técnicas.

**Tercera etapa:** Se lleva a cabo la fase de clasificación incluyendo los clasificadores empleados individuales y combinados mediante diferentes técnicas. Por un lado se emplea cada matriz obtenida anteriormente (RTF, IRTF, IRTF reducida) como entradas de los clasificadores a emplear. El éxito en la detección de FV depende de la estructura de los clasificadores utilizados. Con el propósito de adaptarse mejor a los datos, se debe ajustar parámetros y así obtener en lo posible el de mejor rendimiento.

### 3.3.1 Técnicas de pre-procesamiento de la señal ECG

En esta sección se explican brevemente los principales métodos de reducción del ruido presente en el ECG que se encuentran en la literatura y aquellos métodos utilizados para esta investigación como son: los de reducción de la línea base y los de inventanado de ECG para detección de FV.

Durante el procesamiento automático de la señal, la presencia de perturbaciones puede producir errores en el diagnóstico. Los ruidos pueden ser:

- Ruido debido al registro de la actividad de los músculos más cercanos, al movimiento del electrodo, etc.
- Interferencia de red (50/60 Hz), la cual es debida a la presencia de dispositivos de instrumentación cercanos al paciente y/o conectados a la red eléctrica.
- Variaciones de la línea base, las cuales aparecen principalmente por la respiración del paciente, y se determinan mediante componentes de baja frecuencia, etc.

Estos ruidos deben ser reducidos para que las siguientes fases del proceso de análisis ofrezcan unos resultados con una precisión satisfactoria.

La señal adquirida representada como la suma de todos estos elementos, se describe en la ecuación 5.

$$x = \text{ECG} + m + r + b \quad (5)$$

Donde ECG es la señal electrocardiográfica real creada por la actividad cardíaca que se desea registrar, **m** es el ruido en general, **r** es la interferencia de la red eléctrica, y **b** son las variaciones en la línea base.

El objetivo de los algoritmos de pre-procesamiento es el de disminuir al máximo las contribuciones de  $\mathbf{r}$ ,  $\mathbf{m}$  y  $\mathbf{b}$  para que la señal lograda  $\mathbf{x}$  sea lo más parecida a la señal real del ECG.

La reducción de ruido en el ECG ha sido uno de los temas más estudiados en la bibliografía sobre el procesado de señales. En varios estudios se han utilizado diversas maneras de enfrentar el problema, aplicando diferentes métodos universales a todas las fuentes de ruido. En los siguientes apartados se explican brevemente los principales métodos de reducción de ruido, así mismo, se presentan los algoritmos según el tipo de ruido que eliminan.

### **3.3.1.1 Métodos para la reducción de las variaciones de la línea base**

Las variaciones de la línea base se pueden producir debido a varios factores como la respiración, el movimiento del paciente durante la adquisición del electrocardiograma y los cambios en la impedancia de los electrodos. Estas variaciones crean interferencias de baja frecuencia en el rango de 0 a 0.5 Hz, las cuales deben ser reducidas para no modificar el resultado de procesos posteriores.

A continuación se describen varios métodos para reducir las variaciones de la línea base: Un primer paso utiliza filtros de paso banda de 0.5Hz a 100 Hz, o de paso alto con una frecuencia de corte de 0.5 Hz. En [38] se usa un filtro paso alto de respuesta impulsional infinita (*IIR-Infinite Impulse Response*) con una frecuencia de corte de 0.5 Hz. En [39] Jacek, usa un banco de filtros no lineales. En [40] Luo comenta diferentes filtros IIR. Rangayyan y Leif describen los tipos de filtrado de baja frecuencia para señales biomédicas [33], [41]. Además, se usan métodos de filtrado adaptativo [38]. En el trabajo [42] se describe una técnica mediante el uso de un filtro variante en el tiempo. En este caso la frecuencia de corte va variando según el análisis de las componentes frecuenciales de cada latido respecto a un promedio de los mismos. Xin [43] se basa en las diferentes escalas de la transformada Wavelet para un filtro de línea base.

### **3.3.1.2 Métodos para la reducción de la interferencia de red (50 Hz, 60Hz)**

En la señal ECG aparece una señal interferente localizada a una frecuencia determinada, debida a la red de alimentación eléctrica [33], [41]. En la red eléctrica europea, la interferencia se localiza en los 50 Hz, mientras que en los Estados Unidos de Norte América está sobre los 60

Hz. Diferentes estudios bibliográficos han usado varios algoritmos de filtrado para éste propósito.

Existen una serie de técnicas realizadas mediante el diseño de filtros digitales para cancelar el efecto de la interferencia de Red [33], [41]. Chang y Pei explican técnicas que permiten cancelar la interferencia de red en el dominio del tiempo usando un filtro IIR notch [44]. Tseng presenta un filtro Fir Notch [45] y Tseng y Pei usa la IIR intentando conseguir una mayor reducción de la interferencia de red [46]. La frecuencia de red no es exactamente de 50 Hz/60Hz, con lo cual el método anterior puede presentar inconvenientes. Para resolver este problema diseña un filtro adaptativo que se ajusta a las variaciones de la frecuencia de la red. Ching se propone un filtro notch adaptativo basado en un algoritmo LMS-*Least Mean Squares*. Yue presenta una técnica para la reducción de la interferencia de red usando el filtro adaptativo notch (RLS- *Recursive Least-Squares* ) [47].

### 3.3.1.3 Métodos para la reducción de diversas fuentes de ruido

Además de las interferencias generadas por las oscilaciones de la línea base y la red eléctrica, existes diversos tipos de ruido que aparece en la señal ECG que puede ser debido a múltiples factores: el ruido debido al interfaz electrodo-paciente, señales eléctrico generados por parte de los músculos del cuerpo humano electromiograma (EMG), sistema de medida, etc.

En el ruido muscular, sus componentes frecuenciales pueden llegar hasta los 500 Hz, el cual es producido por la actividad de los músculos más cercanos al corazón. Por lo tanto, uno de los pasos en el procesado de la señal ECG será la reducción de las interferencias de ruido muscular [33], [41].

Se exponen brevemente algunos de los métodos principales de reducción del ruido muscular: Se usan métodos basado en la respuesta al impulso finita (FIR) [48]. Además se usa el filtro de media móvil [49]. La transformada wavelet también se utiliza [50], [51], [52]. Existen varios métodos que, utilizando un filtrado adaptativo, consiguen cancelar parte del ruido del ECG [35]. Rahman propone diferentes estructuras de filtros adaptativos basados en el algoritmo LMS [53]. Además, Diversi, mediante un sistema basado en una extensión de filtros Kalman, logra la reducción de ruidos simétricos con varianza mínima [54]. [55], [56]. [57]. El método descrito por Melten utiliza el filtrado Wiener para reducir la influencia del ruido muscular en

espectroscopia [58] [59]. Se mencionan otras citas que hacen referencia al interfaz electrodo-paciente [60] etc.

### 3.3.1.4 Filtros para eliminar la línea base

El primer paso del procesado de la señal ECG, consiste en realizar una comprobación empleando diferentes filtros de la línea base; IIR, FIR, Media Móvil, Smooth, Wavelet y Mediana, comparando sus rendimientos para reducción de la variación de la línea base así como atenuar su presencia en la señal, con el propósito de obtener una mejor calidad y definición de la señal temporal que redundará en mejores características proporcionadas por la RTF. Este procesamiento comienza con la implementación de un filtro de respuesta impulsional infinita (IIR) de orden 8 con una respuesta Butterworth tipo paso banda rango 1Hz a 45Hz [61] [62]. Este filtro es recursivo que tiene retroalimentación de la salida a la entrada. Por lo tanto, la salida es una función de las muestras de salida anteriores y las muestras de entradas pasadas, descrita en la ecuación 6 que considera un filtro digital con entrada  $x[n]$  y salida  $y[n]$ .

$$y(n) = \sum_{k=0}^N a_k x(n-k) + \sum_{k=0}^N b_k x(n-k) \quad (6)$$

Donde  $a_k$  y  $b_k$  son los coeficientes del filtro. La función de transferencia del filtro IIR se puede expresar usando transformada Z como muestra en la ecuación 7.

$$H = \frac{\sum_{k=0}^N b_k z^{-k}}{1 + \sum_{k=0}^N a_k z^{-k}} \quad (7)$$

El efecto de la aplicación de este filtro paso banda, donde la señal original de tipo ‘Normal’ está representada en azul, y la señal de salida representada en color rojo marca una reducción de la línea base. Además, se muestra su respuesta frecuencial que rechaza todas las señales no situadas en su rango de frecuencias, eliminando variaciones que crean interferencias de baja frecuencia de la línea base como indica la figura 16.

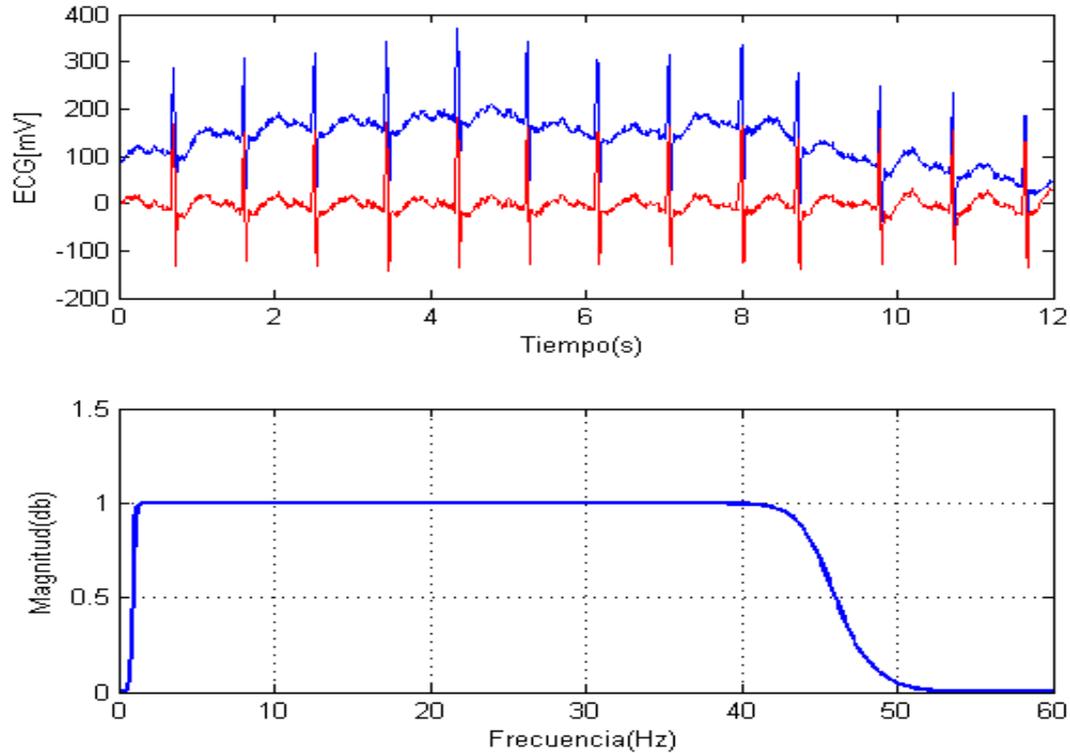


FIGURA 16. FILTRADO PASA-BANDA IIR APLICADO A SEÑAL ECG DE TIPO 'NORMAL', SEÑAL DE ENTRADA EN COLOR AZUL, SEÑAL DE SALIDA FILTRADA EN COLOR ROJO, SU RESPUESTA EN FRECUENCIA.

La segunda técnica emplea el filtro de FIR de orden ( $N = 150$ ) de tipo paso banda rango 1Hz a 45Hz. Para obtener la salida solo se basa en entradas actuales y anteriores, observado en la ecuación 8.

$$y(n) = \sum_{k=0}^N b_k x(n - k) \quad (8)$$

Donde  $b_k$  el coeficiente de filtro. La función de transferencia del filtro FIR puede expresarse aplicando la transformación Z como se describe en la ecuación 9.

$$H = \sum_{k=0}^N b_k z^{-k} \quad (9)$$

Los resultados obtenidos de la eliminación de la línea base son los que se presentan en la figura 17, donde en la parte superior se muestra la señal original de tipo 'Normal' representada en azul junto con su señal filtrada representada en color rojo y en la parte inferior se representa su

respuesta en frecuencia. Se observa como la señal original, representada en azul, tiene más oscilaciones con relación a la salida de color rojo, eliminando las frecuencias más bajas.

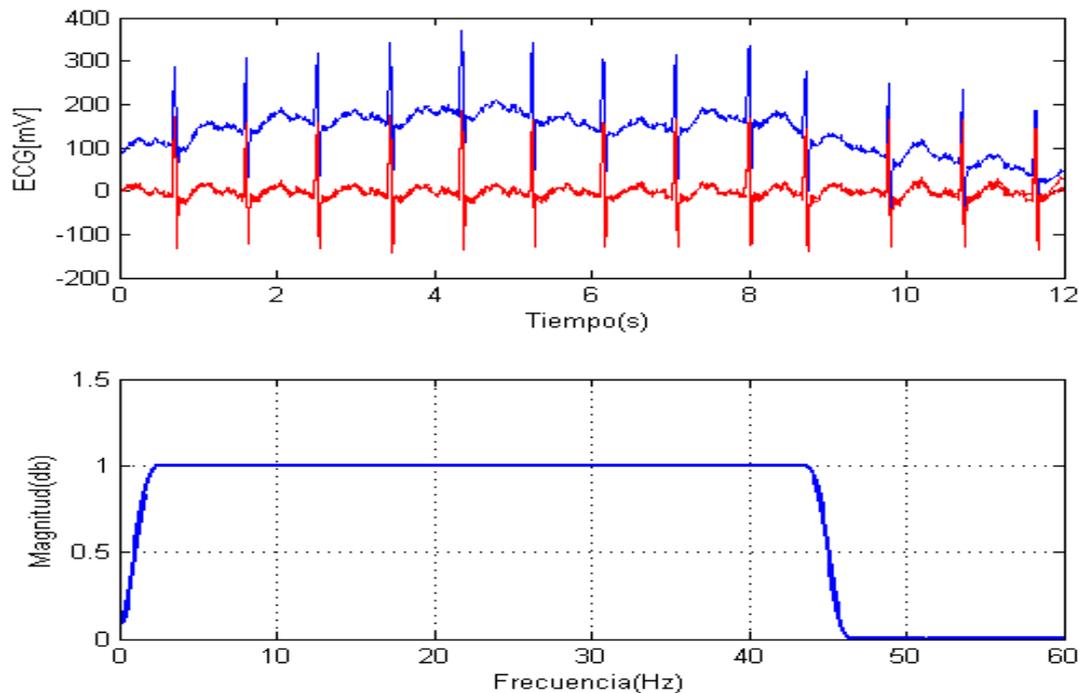


FIGURA 17. FILTRADO PASA-BANDA FIR APLICADO A SEÑAL ECG DE TIPO 'NORMAL', SEÑAL DE ENTRADA EN COLOR AZUL, SEÑAL DE SALIDA FILTRADA EN COLOR ROJO, SU RESPUESTA EN FRECUENCIA.

La tercera técnica de filtrado consiste en la aplicación de la transformada Wavelet para reducir las variaciones de la línea base, en concreto un Wavelet madre con descomposición de  $N$  niveles. El análisis Wavelet permite descomponer la señal original  $x$  en aproximaciones ( $cA_i$ ) y detalles ( $cD_i$ ) con  $i = \{1, 2, \dots, N\}$ , las aproximaciones son los componentes de baja frecuencia de la señal mientras que los detalles son las componentes de alta frecuencia de la misma. El ejemplo del proceso de  $N=3$  se lo puede apreciar en la figura 18, donde el primer paso, la señal original  $x$  pasa a través de dos filtros  $g$  paso alto y  $h$  paso bajo. La señal de salida del filtro  $g$  contiene los coeficientes de detalle mientras, que la señal de salida del filtro  $h$  corresponde a los coeficientes de aproximación de la señal. Posteriormente se realiza el mismo proceso para cada línea de la señal.

Se ha realizado en este trabajo la descomposición de la señal en 5 niveles como se observa en la parte superior de la figura 19, en donde el orden de estas subseñales de arriba abajo es el

siguiente: detalle nivel1, detalle nivel2, detalle nivel3, detalle nivel4 y aproximación último nivel.

En la parte baja de la misma figura se observa la señal original representada en azul, y en verde la señal de salida que representa a la línea base correspondiendo a la aproximación nivel5. También se aprecia que al sacar la diferencia entre ellas, permite eliminar las frecuencias más bajas resultando una disminución de la línea base.

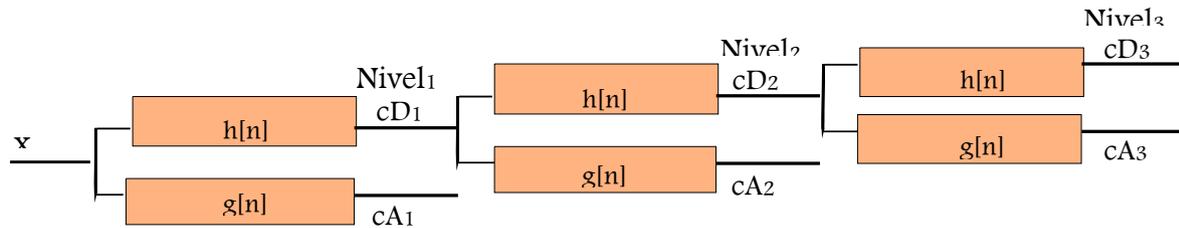


FIGURA 18. DESCOMPOSICIÓN DE 3 NIVELES.

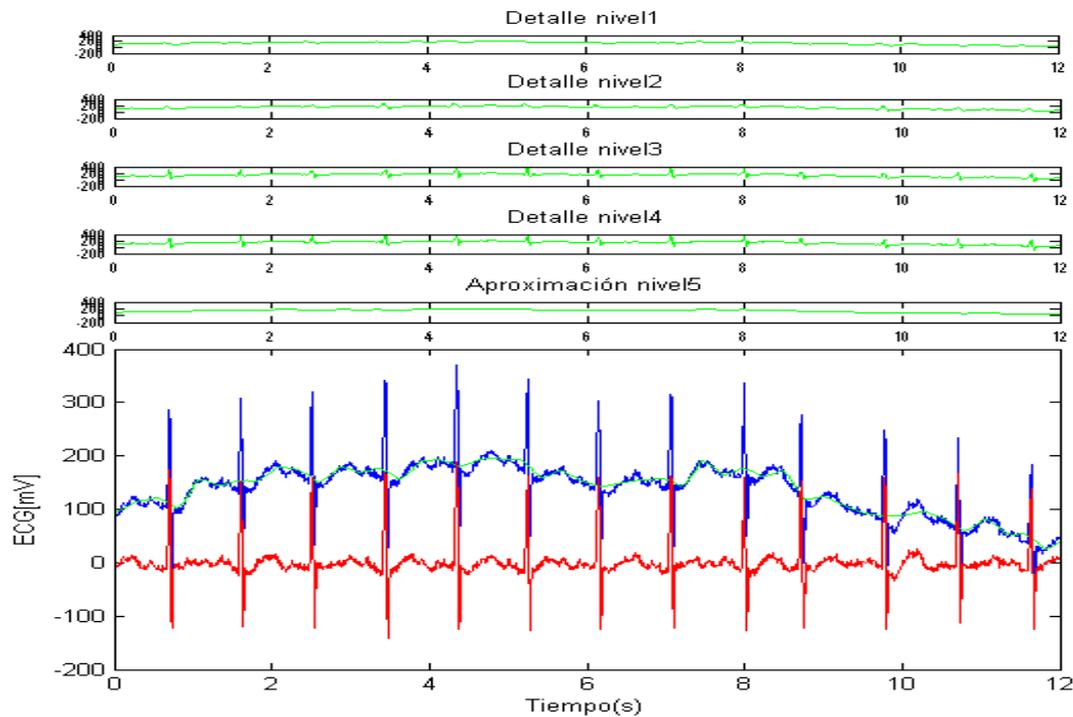


FIGURA 19. LA SEÑAL ORIGINAL, REPRESENTADA EN AZUL, Y LA SEÑAL FILTRADA, REPRESENTADA EN COLOR ROJO, Y CÓMO ELIMINA LA FLUCTUACIÓN DE LA LÍNEA BASE EMPLEANDO WAVELET MADRE DE TIPO SYM4.

También se emplea otra técnica usando filtro de media móvil, de tipo paso bajo que se encarga de rechazar las señales de frecuencias superiores a las de la línea base y posteriormente permite obtener la diferencia entre ellas eliminando las frecuencias más bajas con una disminución de la línea base.

Esta técnica opera con un promedio de N elementos de la señal de entrada para producir cada elemento de la señal de salida como muestra en la ecuación 10.

$$y(n) = \frac{1}{N} \sum_{k=0}^{N-1} x(n-k) \quad (10)$$

Representación frecuencial se puede apreciar en la ecuación 11.

$$y(n) = \frac{x[n] + x[n-1] + \dots + x[n-N+1]}{N} \Rightarrow \frac{y(z)}{x(z)} = \frac{z^{N-1} + z^{N-2} + \dots + z + 1}{Nz^{N-1}} \quad (11)$$

En la figura 20 en su parte superior se muestra la señal original en azul mientras que la línea base en verde y la señal filtrada con la disminución de la línea base en color rojo. En la parte inferior se encuentra su respuesta frecuencial.

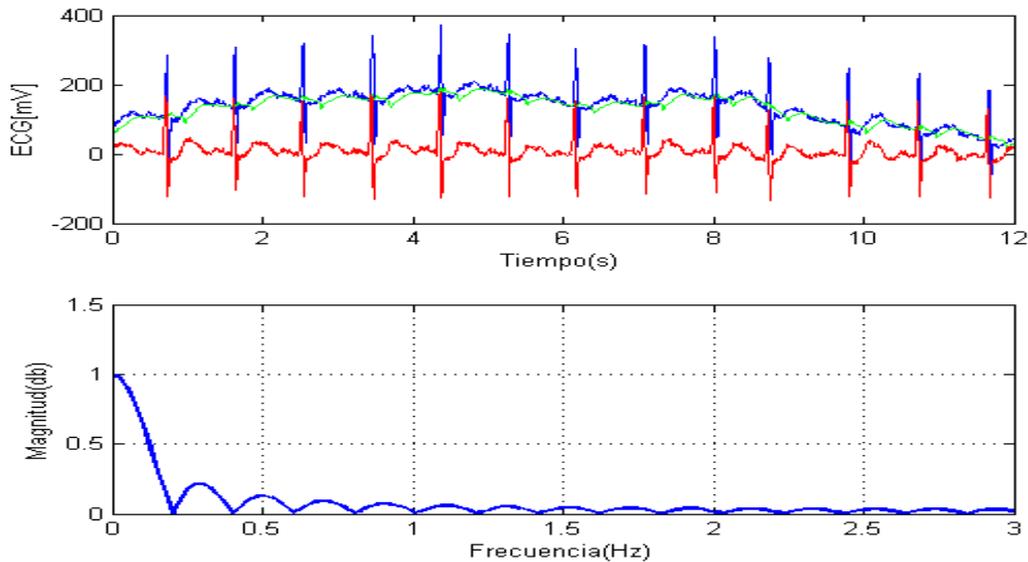


FIGURA 20. LA PARTE SUPERIOR PRESENTA LA SEÑAL ORIGINAL EN COLOR AZUL Y LA SEÑAL FILTRADA EN COLOR ROJO, MOSTRANDO LA ELIMINACIÓN DE LA FLUCTUACIÓN DE LA LÍNEA BASE MEDIANTE EL FILTRO DE MEDIA MÓVIL (N=31). EN LA PARTE INFERIOR SE PRESENTA SU RESPUESTA FRECUENCIAL.

Se utilizó también el filtro de mediana que reemplaza cada punto de la entrada  $x(n)$  de la señal ECG por la media de ese punto y un número  $V$  definido de puntos vecinos, la salida  $y(n)$  definido como muestra en la ecuación 12:

$$y(n) = \text{med} \begin{cases} x \left( n - \left( \frac{V-1}{2} \right) : n + \left( \frac{V-1}{2} \right) \right) & \text{si } V \text{ es impar,} \\ x \left( n - \left( \frac{V}{2} \right) : n + \left( \frac{V}{2} \right) \right) & \text{si } V \text{ es par} \end{cases} \quad (12)$$

Con  $\mp V$  vecinos ( $2V$  muestras en total, incluyendo la central).

En esta prueba se usa filtro de mediana de tipo paso bajo obteniendo bajas frecuencias en la salida. Luego restando entre ellas para obtener señal filtrada con eliminación de la línea base. Los resultados logrados son los que se presentan en la figura 21 donde en la parte superior se observa la señal original en azul, la señal verde representa la línea base y en la parte inferior se observa la señal filtrada en color roja.

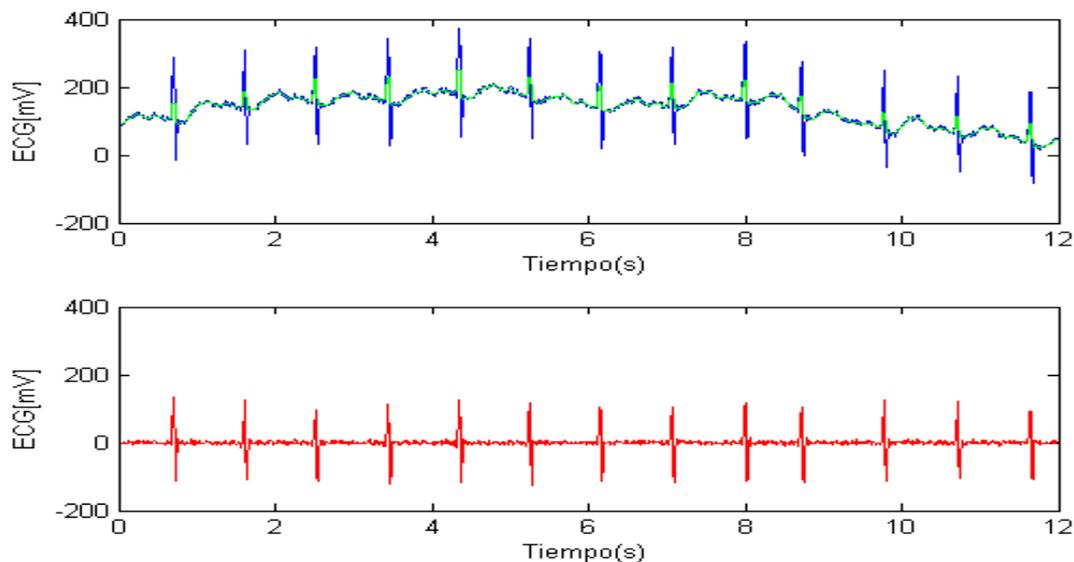


FIGURA 21. LA SEÑAL ORIGINAL REPRESENTADA EN AZUL, LA SEÑAL FILTRADA REPRESENTADA EN COLOR ROJO Y CÓMO ELIMINA LA FLUCTUACIÓN DE LA LÍNEA BASE MEDIANTE EL FILTRO MEDIANA.

Por último se propone el filtro Smooth con el cual se sigue el mismo proceso que con los filtros anteriores. En la figura 22 se observa en la parte superior, la representación de la señal original en azul y la señal de la línea base en color verde. En la parte inferior se muestra la señal filtrada en color rojo.

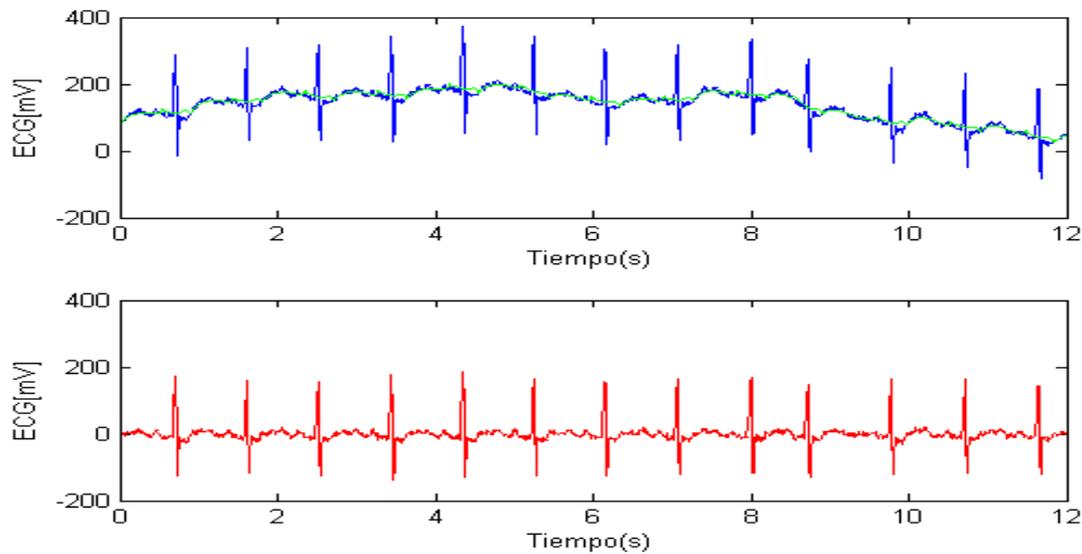


FIGURA 22. LA SEÑAL ORIGINAL, REPRESENTADA EN AZUL, Y LA SEÑAL DE SALIDA, REPRESENTADA EN COLOR ROJO, Y CÓMO ELIMINA LA FLUCTUACIÓN DE LA LÍNEA BASE MEDIANTE EL FILTRO SMOOTH.

A partir de los resultados obtenidos, se observa cómo la señal original tiene una mayor composición de frecuencias o armónicos en comparación con las señales filtradas. Por tanto, se concluye que el filtrado, tanto por IIR, FIR, Media Móvil, Smooth, Mediana y Wavelet, logran disminuir las bajas frecuencias correspondientes a la línea base. Los filtros propuestos son adecuados para su utilización en la detección FV. Cumplen con los requerimientos que habíamos impuesto: reduce adecuadamente la línea base, conserva la mayoría de componentes de señal. Posteriormente en el capítulo 4, después de usar dichos filtros en la detección FV realizamos las comparaciones entre ellos.

### 3.3.1.5 Enventanado de ECG para detección de FV

Una vez filtrada la señal del ECG, el enventanado se realiza con el fin de definir las ventanas de la señal  $V_t$  sobre las que se aplicará la RTF [62]. La estrategia posee dos partes bien diferenciadas: una de ellas es la detección de Máximos Locales (ML) para cada ventana  $V_t$  y la otra es la corrección de ML ya que la distancia entre dos ML consecutivos puede ser demasiado grande o demasiado pequeña. El método general que se implementa sigue las etapas que muestra la figura 23.

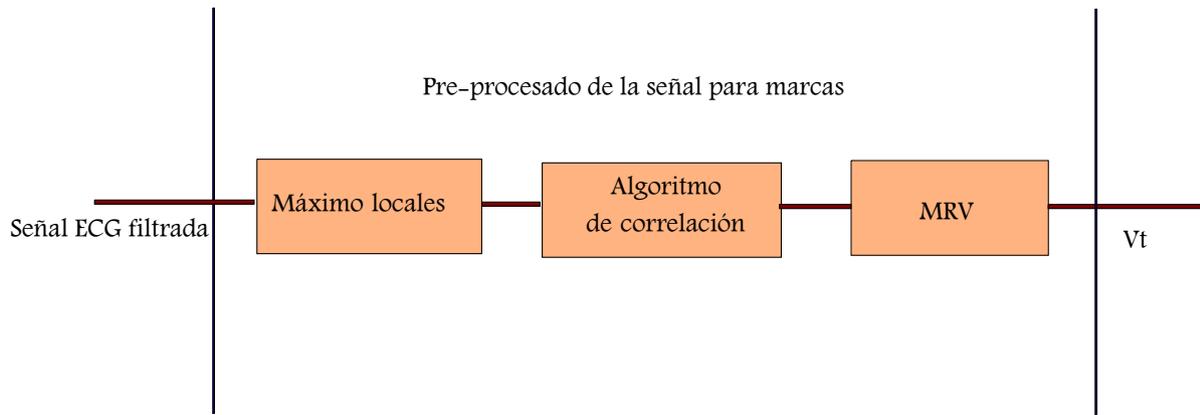


FIGURA 23. EL PROCEDIMIENTO PARA CALCULAR LAS MARCAS DE REFERENCIA DE LAS VENTANAS (MRV) MEDIANTE EL ALGORITMO DE DETECCIÓN DE MARCAS Y EL ALGORITMO DE CORRECCIÓN, Y OBTENER LAS VENTANAS DE TIEMPO.

### 3.3.1.6 Marcas de Referencia de Ventana MRV

Para que las  $V_t$  de las señales ECG sobre las que se aplicará la RTF sean repetidas y en su mayoría similares es necesario obtener unas marcas MRV que indiquen el comienzo de dicha ventana  $V_t$ .

Para poder analizar la señal de forma continua evitando solapes en las ventanas o una distancia excesiva entre ventanas, se ha tenido en cuenta que los rangos normales de frecuencia cardiaca están situados entre 50 y 120 latidos por minutos (lpm) [63], se definen los parámetros  $MRV_{Min}$  y  $MRV_{Max}$  como las distancias mínima y máxima que puede existir entre dos marcas MRV consecutivas, siendo en este caso 0.5 s y 1.2 s, respectivamente.

El procedimiento para calcular las marcas MRV consta de cuatro etapas:

- Primera Etapa: consiste en utilizar un detector de ML de la señal de entrada (la figura 24 en la tercera columna muestran un ejemplo para tipo ‘Normal’, ‘Otros’, ‘TV’ y ‘FV’. El detector de ML fue implementado utilizando la función *findpeaks* de Matlab. Dicha función busca todos los picos en la señal por encima de un valor mínimo, devolviendo su posición dentro de una distancia mínima entre ellos. Las detecciones ML se presentan como puntos rojos, de este modo, se obtiene un vector de marcas con la posición de los picos encontrados, como en la ecuación 13. Siendo  $N_{ML}$  el número de marcas de máximos locales ML encontradas.

$$ML = [ML_i; i = 1, 2 \dots N_{ML}] \quad (13)$$

- Segunda Etapa: Se calcula la distancia entre dos ML consecutivos como en la ecuación 14:

$$DML_i = ML_{i+1} - ML_i; i = 1 \dots (N_{ML} - 1) \quad (14)$$

En algunos casos no aparecen puntos ML por un largo tiempo y se generan distancias grandes que denominamos como DAG (Distancia Atípica Grande). En otros casos aparecen ML muy cercanos, generándose lo que denominamos como DAP (Distancias Atípicas Pequeñas). Si la distancia está dentro del rango  $[MRV_{Min} \text{ } MRV_{Max}]$  tendremos lo que denominamos como DRM (Distancias Regular Medianas). La expresión matemática de este algoritmo es la mostrada en la ecuación 15.

$$DML_i = \begin{cases} DAG \text{ si } DML > MRV_{Max} \\ DAP \text{ si } DML < MRV_{Min} \\ DRM \text{ si Otros casos} \end{cases} \quad (15)$$

- Tercera etapa: Si existen puntos de tipo DAG o DAP, se desarrolla una sistema corrector iterativo que analiza las distancias DML entre dos puntos ML. Cuando se detecta un DAP, se elimina uno de ellos de acuerdo a la distribución de los ML vecinos. Si la distancia detectada es de tipo DAG, se introduce un ML exactamente en la mitad entre los dos puntos ML que determinan dicha distancia. Si a su vez las DML generadas son también de tipo DAG estarán sujetas a la misma operación iterativa. Al finalizar el Proceso iterativo, todos los valores de las distancias DML producidos cumplen la condición indicada en la ecuación 16.

$$DML_j = (MRV_{Min} \leq DML \leq MRV_{Max}) = DRM \text{ con } DML_j = ML_{j+1} - ML_j \quad (16)$$

Donde  $j = 1, 2, \dots, (N_{MLC} - 1)$  siendo  $N_{MLC}$  el número de marcas ML corregidas.

- Finalmente, las marcas MRV se obtienen a partir de las ML corregidas. La figura 24 en la cuarta columna muestra un ejemplo del resultado [62].

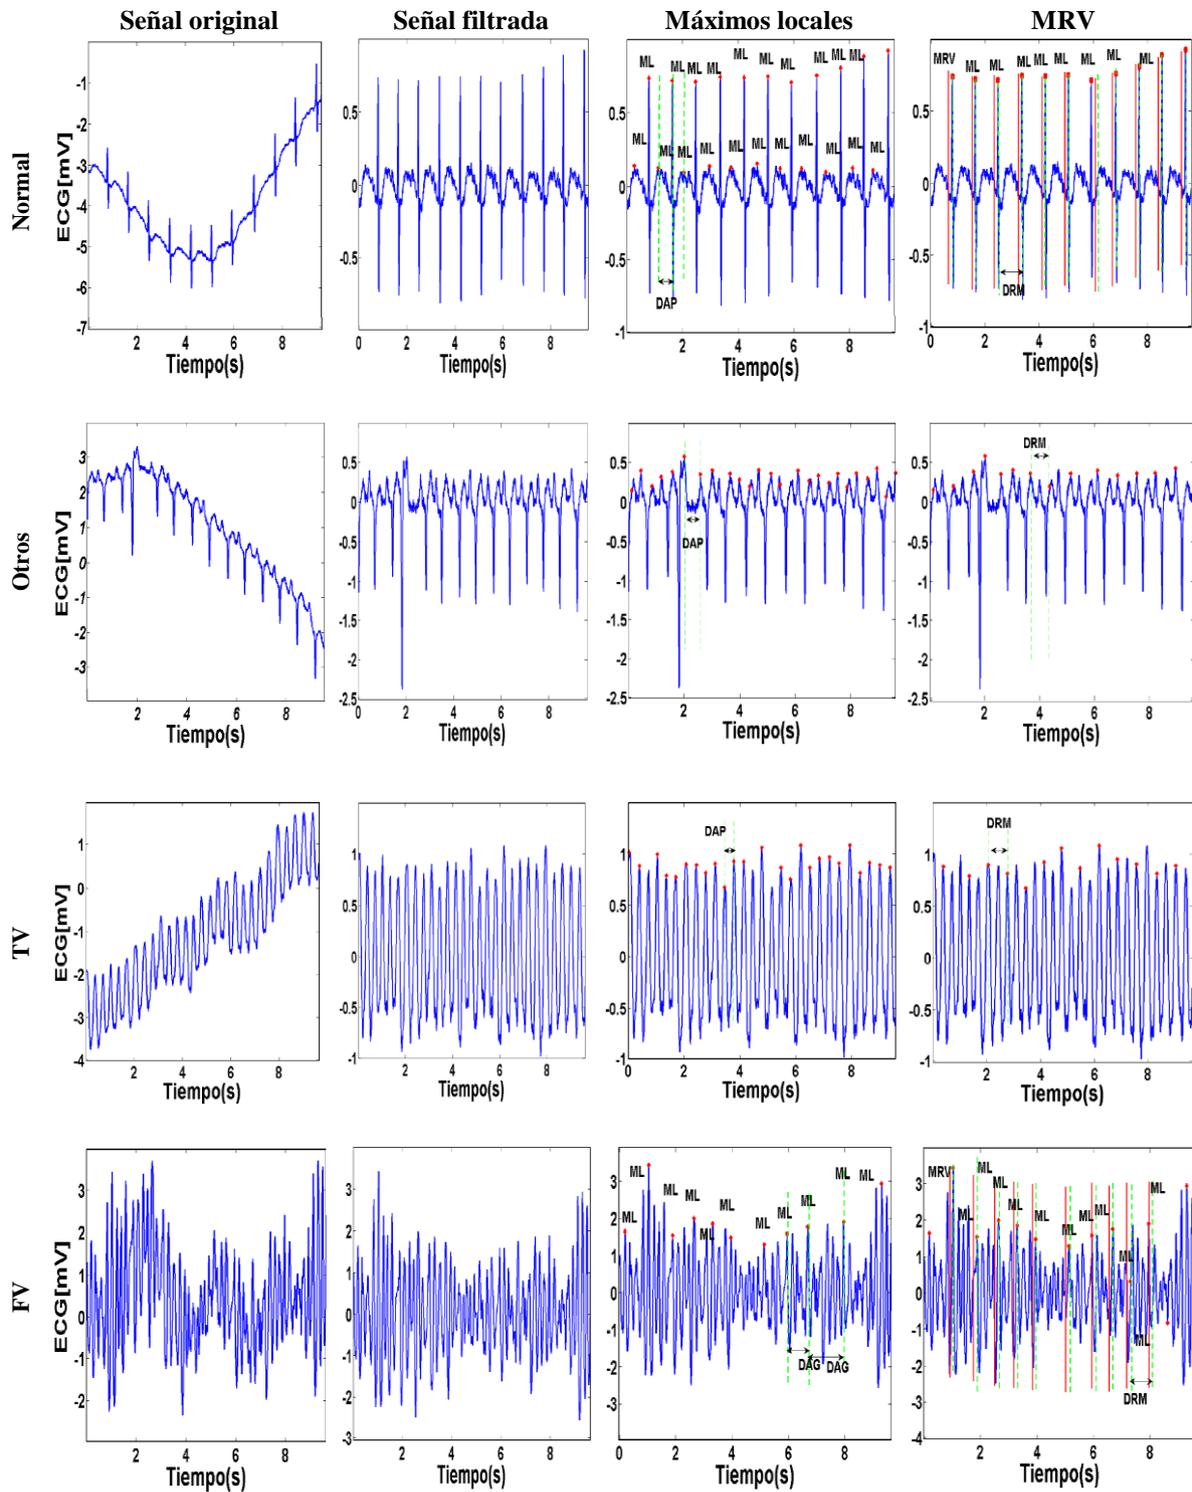


FIGURA 24. SE PRESENTA LAS ETAPAS DE PROCESADO INICIAL DE SEÑAL ECG DE TIPO 'NORMAL', 'OTROS', 'TV' Y 'FV'. CADA COLUMNA REPRESENTA LA MISMA ETAPA. DE IZQUIERDA A DERECHA: SEÑAL ORIGINAL, ETAPA DE ELIMINACIÓN DE OSCILACIÓN DE LÍNEA BASE, PUNTOS ML Y ML CORREGIDOS (PUNTOS ROJOS).

Dado que es habitual que la marca ML coincida con un complejo QRS, se aplica un desplazamiento de tiempo ( $t_{\text{offset}} = 150$  milisegundos (ms)) en la obtención de la ventana  $V_t$  para asegurar que se incluye en la misma ventana un QRS completo en el caso de ritmo sinusal normal. Por tanto, las marcas MRV se definen según la ecuación 17.

$$MRV_j = [ML_j - t_{\text{offset}}; j=1; \dots; N_{MLC}] \quad (17)$$

Una vez que las MRV se obtienen a partir de los ML corregidos, se utiliza cada MRV para generar una ventana  $V_t$  de longitud de 1,2s (150 muestras según la frecuencia de muestreo de los datos) [63], tal y como se muestra en la ecuación 18.

$$V_{t_j} = [MRV_j, MRV_j + 1.2 \text{ s}] \quad (18)$$

Posteriormente, para cada ventana  $V_t$  se calculará la transformada de Hilbert y después se calculará la RTF (ver sección 3.3.2).

### **3.3.2 Representación RTF**

#### **3.3.2.1 Introducción**

Las señales facilitan la información para representar medidas de sistemas en el mundo real, como pueden ser la actividad eléctrica del corazón, las ondas cerebrales las vibraciones de motores, entre otras. Una señal se puede tratar de diferentes maneras, con el objetivo de obtener información adecuada. La mayor parte de estas señales se registran en el dominio del tiempo, pero estos métodos no siempre presentan una representación adecuada, dado que en algunos casos se pierde la información sobre la frecuencia. Esto se puede observar más claramente por medio de un espectro de frecuencias que muestre las frecuencias existentes en la señal. El diagnóstico en el dominio de frecuencia utiliza métodos como la Transformada de Fourier (TF). Dicha técnica ha sido una herramienta muy útil durante varios años en el procesamiento de señales, y en particular muy favorable para las señales estacionarias. La mayoría de las señales de interés científico presentan características no estacionarias como en el caso de las señales biomédicas. En este sentido la TF representa una limitación para analizar las señales no estacionarias, pues cuando se pasa al dominio de la frecuencia se pierde toda información temporal. Para superar las limitaciones del método espectral basado en TF, algunas técnicas de análisis de señales no estacionarias como el ECG han empleado métodos que se pueden representar adecuadamente usando una distribución tiempo-frecuencia (*TFD-Time Frequency*

*Distribution*). En la misma se distribuye la energía de la señal en el espacio bidimensional tiempo-frecuencia. También, en el procesamiento de la señal, se pueden emplear las características extraídas por la concentración de la energía en dos dimensiones (tiempo y frecuencia) en vez de solo una (tiempo o frecuencia) [64]. La visión de procesamiento en el dominio tiempo-frecuencia se conoce en 1932 cuando Wigner implemento la distribución de (WD-*Wigner Distribution*) en el entorno de la mecánica cuántica como una función de la posición y el momento [65]. En 1946 se introdujo la representación de señales habladas [66] usando la transformada en tiempo corto de Fourier (STFT-*Short Time Fourier Transform*). Cohen recomendó una clase completa de distribuciones tiempo-frecuencia basadas en la WVD en 1966 [67].

### 3.3.2.2 Aplicación del análisis tiempo-frecuencia

#### 3.3.2.2.1 Transformada de Fourier

La TF es uno de los métodos más usados para el análisis de señales. Se usa para transformar la señal de un dominio temporal a otro dominio. Se conoce como el espectro de frecuencia del que se puede extraer información de rendimiento. La TF expresa una función periódica como una suma de exponenciales complejas periódicas [68], [69].

Se puede definir la TF de una función no periódica como muestra en la ecuación 19.

$$F(x) = X(f) = \int_{-\infty}^{+\infty} x(t)e^{-2j\pi ft} dt \quad (19)$$

A continuación estudiamos algunas de las propiedades más relevantes de TF [69].

#### Propiedades básicas de la TF:

##### Linealidad de la transformada de Fourier:

Para que la TF sea lineal, debe cumplir la siguiente fórmula:

$$x = x_1(t) + a_2x_2(t) \xrightarrow{F} a_1X_1(f) + a_2X_2(f) \quad (20)$$

Donde:  $x_i \mathbb{R} \rightarrow \mathbb{R}, \alpha_i \in \mathbb{R}$  con  $i = \{1, 2\}$

##### Cambio de escala:

Si  $x(t)$  es una función continua y totalmente integrable en  $\mathbb{R}$  la TF de un grupo de escala se cumple la ecuación 21:

$$x(\beta t) \xrightarrow{F} \frac{1}{|\beta|} X\left(\frac{f}{\beta}\right), \text{ donde } \beta \in \mathbb{R} \setminus \{0\} \quad (21)$$

**Translación:**

Si existe la TF de  $x(t)$ , la translación se cumple por la ecuación 22:

$$x(t - a) \xrightarrow{F} X(f)e^{-2j\pi fa}, \quad a \in \mathbb{R} \quad (22)$$

**Derivación:**

Si  $x(t)$  es una función continua y derivable, la TF se cumple por la ecuación 23:

$$x'(t) \xrightarrow{F} iX(f) \quad (23)$$

**Convolución en el dominio t:**

Si  $x_1(t)$  y  $x_2(t)$  absolutamente integrables en  $\mathbb{R}$ , la convolución (\*) se cumple en la ecuación 24:

$$x_1(t) * x_2(t) \xrightarrow{F} X_1(f) \cdot X_2(f) \quad (24)$$

Análogamente, la multiplicación (.) se cumple en la ecuación 25:

$$x_1(t) \cdot x_2(t) \xrightarrow{F} X_1(f) * X_2(f) \quad (25)$$

**3.3.2.2 Densidad de energía en tiempo y frecuencia:**

Según el teorema de Poynting, en base a las ecuaciones de Maxwell en la teoría electromagnética, la densidad de energía es el valor absoluto del cuadrado de la intensidad del campo eléctrico (o del campo magnético) [70].

La energía total de la señal se conseguirá por la integral de la densidad de energía para todo tiempo  $t$ , como muestra en la ecuación 26:

$$E = \int_{-\infty}^{+\infty} |x(t)|^2 dt \quad (26)$$

Del mismo modo, se puede obtener la media temporal de la energía de la señal, como se observa en la ecuación 27:

$$\langle t \rangle = \int_{-\infty}^{+\infty} t|x(t)|^2 dt \quad (27)$$

Y por consiguiente, la desviación estándar  $\sigma_t$  como aprecia la ecuación 28:

$$\sigma_t^2 = \langle t^2 \rangle - \langle t \rangle^2 \quad (28)$$

La media nos muestra donde está concentrada la energía de la señal, la desviación estándar nos brinda información respecto a su duración.

La energía estimada a partir de la forma de onda temporal es equivalente a la integral de  $|X(f)|^2$  durante todas las frecuencias, y es conocida como el teorema de Parseval o de Rayleigh [71]. Se representa con la ecuación 29.

$$E = \int_{-\infty}^{+\infty} |x(t)|^2 dt = \int_{-\infty}^{+\infty} |X(f)|^2 df \quad (29)$$

De la misma forma que en el caso temporal, la frecuencia media se define como muestra la ecuación 30:

$$\langle f \rangle = \int_{-\infty}^{+\infty} f|X(f)|^2 df \quad (30)$$

Y la desviación estándar  $\sigma_f$  de las frecuencias conocido como ancho de banda como se observa en la ecuación 31:

$$\sigma_f^2 = \langle f^2 \rangle - \langle f \rangle^2 \quad (31)$$

### 3.3.2.3 La señal analítica

La señal analítica de Gabor es una señal compleja en la cual su parte real es igual a la señal original, y en donde su espectro de frecuencias es nulo para frecuencias negativas, se puede calcular como en la ecuación siguiente [72].

$$z(t) = x_r(t) + jx_i(t) = A(t)e^{j\varphi(t)} \quad (32)$$

Donde  $z(t)$  es una señal compleja,  $x_i(t)$  parte imaginaria,  $x_r(t)$  parte real.

La amplitud y la fase se definen en las ecuación 33 y 34 [73], [74].

$$A(t) = \sqrt{x_r^2(t) + x_i^2(t)} \quad (33)$$

$$\varphi(t) = \arctan\left(\frac{x_r(t)}{x_i(t)}\right) \quad (34)$$

Y la frecuencia instantánea se calcula como la derivada de la fase respecto al tiempo [75], [76] como se muestra la ecuación 35:

$$\omega_i(t) = \varphi'(t) \quad (35)$$

En caso de la señal real  $x(t)$  donde su TF es  $X(f)$ , la señal compleja  $z(t)$  con su espectro está compuesto sólo por las frecuencias positivas de  $X(f)$  se obtiene por la transformada inversa de  $X(f)$  donde la integración sólo contiene las frecuencias positivas como se puede observar en la ecuación 36:

$$z(t) = 2 \frac{1}{\sqrt{2\pi}} \int_0^{+\infty} X(f) e^{j2\pi ft} df \quad (36)$$

El factor 2 es agregado para que la parte real de la señal analítica sea similar a  $x(t)$ . Combinando la expresión del espectro de  $x(t)$ .

$$X(f) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} x(t) e^{-j2\pi ft} dt \quad (37)$$

Se tiene como resultado la estructura de  $z(t)$  en función de la señal original usando las ecuaciones 36 y 37, se muestra en la ecuación [77]:

$$z(t) = x(t) + TH[x(t)] \quad (38)$$

Donde la segunda parte de la ecuación corresponde a la Transformada de Hilbert de la señal se describe en la ecuación 39:

$$TH[x(t)] = \frac{j}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (39)$$

### 3.3.2.4 Principio de incertidumbre de heisenberg

En el análisis tiempo-frecuencia de una señal, aparece la dificultad de no conocer el momento justo donde existe el componente del tiempo y la frecuencia. Es decir llega un tiempo límite en el cual el ancho de banda de una frecuencia y el tiempo, no puede ser mejorado simultáneamente. Este problema de resolución del tiempo y de la frecuencia es resultado del uso del principio de incertidumbre de Heisenberg (como muestra la ecuación 40) que fue desarrollado como la imposibilidad de determinar el momento y la posición de una partícula en la mecánica cuántica.

El principio de Heisenberg se puede resumir de la siguiente manera:

- Ventana ancha: Buena resolución en el dominio de la frecuencia y mala resolución en el dominio del tiempo.
- Ventana estrecha: Buena resolución en el tiempo y mala resolución en el dominio de la frecuencia.

La elección de una ventana adecuada para el análisis, depende de la aplicación.

$$\sigma_t \sigma_\omega \geq \frac{1}{2} \quad (40)$$

Esta relación se encuentra detalladamente en [69].

### 3.3.2.5 Definiciones y propiedades de las RFT

Una RTF es una superficie tridimensional cuyos ejes son el tiempo y la frecuencia, y en la que cada par (t, f) representa un valor de amplitud que se llama "energía". Los valores de amplitud conseguidos se emplean para conocer la forma de la señal en el plano tiempo-frecuencia y para calcular el valor de la concentración de la intensidad en cada punto de la distribución global. Se puede apreciar la evolución de dicha amplitud en el tiempo y la frecuencia como se muestra en la figura 25.

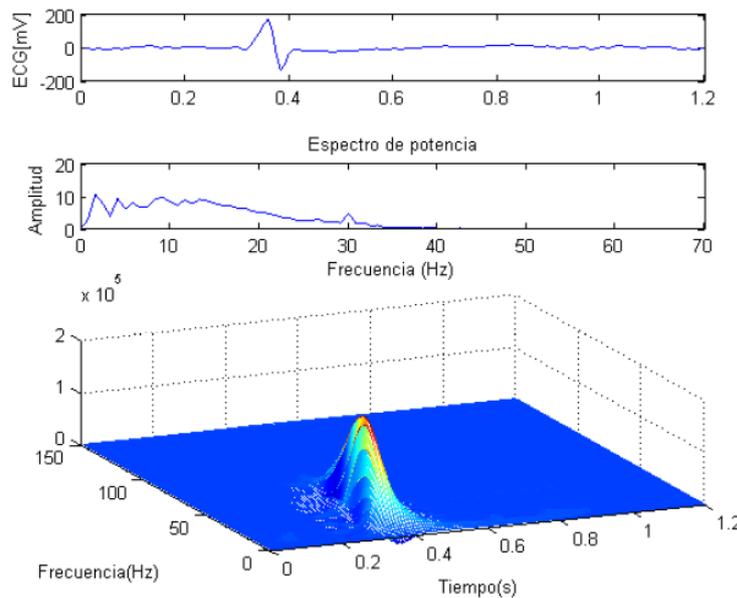


FIGURA 25. EJEMPLO ESPECTRO DE POTENCIA Y LA DE DISTRIBUCIÓN PSEUDO-WIGNER-VILLE EN TIEMPO Y FRECUENCIA DE LA SEÑAL ECG 'NORMAL'.

Así, la RTF obtenida está compuesta por una matriz de valores de "energía".

Se conocen distintas propiedades de las representaciones tiempo-frecuencia [78], [36], [79], las cuales mencionaremos a continuación:

**Covarianza al corrimiento en frecuencia:**

Si la señal se corre en frecuencia  $f_0$ , tenemos que la RTF de ésta señal se debe correr también en frecuencia  $f_0$  como muestra la ecuación 41.

$$y(t) = x(t)e^{j2\pi f_0 t} \rightarrow Y(f) = X(f - f_0) \rightarrow T_y(t, f) = T_x(t, f - f_0) \quad (41)$$

**Covarianza al corrimiento en el tiempo:**

La traslación  $t_0$  en el tiempo de la señal, se debe mantener en su RTF se puede apreciar en la ecuación 42.

$$y(t) = x(t - t_0) \rightarrow T_y(t, f) = T_x(t - t_0, f) \quad (42)$$

**Covarianza a la escala:**

Cuando el eje de tiempo de la señal se multiplica por un factor de escala  $a$ , el eje de tiempo de su RTF se debe multiplicar por el mismo factor  $a$ , y su eje de frecuencia se divide por el factor se describe en la ecuación 43.

$$y(t) = \sqrt{|a|}x(at) \rightarrow T_y(t, f) = T_x\left(at, \frac{f}{a}\right) \quad (43)$$

**Covarianza a la convolución:**

Si dos señales convolucionan en el dominio del tiempo, será equivalente a convolucionar sus correspondientes RTF en el dominio del tiempo como se puede observar en la ecuación 44.

$$y(t) = \int_{-\infty}^{+\infty} h(t - \tau)x(\tau)d\tau \rightarrow T_y(t, f) = \int_{-\infty}^{+\infty} T_h(t - \tau, f)T_x(\tau, f)d\tau \quad (44)$$

**Covarianza a la modulación:**

Cuando dos señales se modulan en el tiempo, sus transformadas de Fourier se convolucionan en frecuencia, por consiguiente la RTF de la señal obtenida debe ser similar a la convolución en frecuencia de las dos RTF de las dos señales se puede apreciar en la ecuación 45.

$$y(t) = h(t)x(t) \rightarrow Y(f) = \int_{-\infty}^{+\infty} H(f - \theta)X(\theta)d\theta \rightarrow T_y(t, f) = \int_{-\infty}^{+\infty} T_h(t, f - \theta)T_x(t, \theta)d\theta \quad (45)$$

**Real:**

Para que una TFD sea real, debe cumplir la siguiente ecuación 46:

$$T_x(t, f) = T_x^*(t, f), \quad \forall x(t) \quad (46)$$

**Positiva :**

Se cumple si una RTF se va a interpretar como una distribución bidimensional de energía de la señal según la ecuación 47.

$$T_x(t, f) \geq 0, \quad \forall x(t) \quad (47)$$

**Localización en frecuencia:**

Esta establece que si la señal es una senoide compleja y su TF está perfectamente concentrada alrededor de cierta frecuencia  $f_0$ , su RTF también debe estar perfectamente concentrada alrededor de esta misma frecuencia, se describe en la ecuación 48.

$$X(f) = \delta(f - f_0) \rightarrow T_x(t, f) = \delta(f - f_0) \quad (48)$$

Donde  $\delta(\cdot)$  es la función impulso unitario.

**Localización en tiempo:**

Esta indica que, si la señal es un impulso perfectamente localizado en el tiempo  $t_0$ , entonces su RTF también debe estar concentrada en el tiempo  $t_0$  se puedes ver en la ecuación 49.

$$x(t) = \delta(t - t_0) \rightarrow T_x(t, f) = \delta(t - t_0) \quad (49)$$

Hay una gran cantidad de técnicas para calcular la RTF, que es posible distinguirlas en dos clase principales: la estimación paramétrica y la no paramétrica.

Las técnicas paramétricas necesitan un modelo previo de la señal, el cual, en general, es difícil de conseguir en las bioseñales debido a su naturaleza.

Por este motivo, se elige un análisis no paramétrico, el mismo puede aplicarse de manera más flexible a bioseñales puesto que no es necesario obtener un modelo concreto de la señal; además, tiene un buen resultado en el tratamiento de señales no estacionarias. Estas técnicas no paramétricas pueden ser fraccionadas principalmente en dos clases: la clase de descomposiciones atómicas (lineales) y la clase de distribuciones energéticas (cuadráticas) [80].

En los últimos años se han desarrollado diferentes representaciones RTF dependiendo de la aplicación. Las principales clases de distribuciones tiempo-frecuencia son [81]: la clase afín de RTF [36], la clase de Cohen de RTF covariantes [69], la clase de potencia [82], y la clase hiperbólica [83], [84].

**Formas lineales (clases de descomposiciones atómicas):**

Reciben el nombre lineal ya que en su obtención, la señal a analizar no se multiplica por sí misma como en el caso de las TFR cuadráticas (bilineales), y además cumplen el principio de superposición. Se proyecta la señal en el plano de manera que se obtienen celdas que conforman la representación global. Como representantes principales se encuentran la transformada corta de Fourier, la transformada de Wavelet y transformada de Gabor, las cuales se describen a continuación.

**Transformada Corta de Fourier**

El estudio de Fourier estándar TF faculta la descomposición de una señal en componentes sinusoidales de diferentes frecuencias, perdiendo la información de tipo temporal puesto que con este estudio no se muestra cuándo ocurren estas frecuencias. Por lo tanto, es necesario realizar un análisis utilizando ventanas cortas en el tiempo, con el propósito de estudiar las frecuencias en cada una de estas ventanas, y conseguir una representación espectral en el tiempo.

La transformada corta de Fourier (*STFT-Short Time Fourier Transform*) soluciona el problema del análisis de señales no estacionarias, fue introducida en 1945 por Gabor. Se basa en dividir la señal en diferentes ventanas temporales con la siguiente ecuación 50:

$$T_{STFT}(t, f) = \int_{-\infty}^{+\infty} x(\tau) g(\tau - t) e^{-j2\pi\tau f} d\tau \quad (50)$$

Donde  $g(\tau)$  es la función ventana, y  $x(\tau)$  es la señal a ser transformada.

Se usa una ventana con respuesta al impulso de un filtro paso bajo, pero se pueden aplicar otras ventanas complejas (Gabor, Hamming, Blackman,..) [85], [86]. Por ejemplo, si se aplica una ventana gaussiana, la STFT se convierte en la transformada de Gabor.

La STFT también se puede definir en el dominio de la frecuencia [68] como se puede observar en la ecuación 51:

$$T_{\text{STFT}}(t, f) = e^{-j2\pi ft} \int_{-\infty}^{+\infty} X(\theta) G(\theta - f) e^{-j2\pi\theta t} d\theta \quad (51)$$

Según la ecuación (51), al dividir la señal en el dominio del tiempo con una ventana  $g(\tau - t)$ , se genera un enventanado en el dominio espectral con la ventana  $G(\theta - f)$ , siendo  $G(f) = F\{g(t)\}$ .

Así, es obtenida la TF de la señal resultante mientras la ventana está desplazada a lo largo del eje de tiempo, produciendo un espectro en una representación bidimensional, como se puede ver en la figura 26.

La figura 26 muestra que no sólo se conocen las componentes de las frecuencias de la señal, sino también su localización en el tiempo.

En la STFT siempre se preserva el mismo tamaño de ventana de tiempo, sin embargo, hay señales no estacionarias cuyo contenido espectral cambia rápidamente, con lo cual una reducción de la ventana en el tiempo, involucra una reducción de la resolución en frecuencia, y viceversa. La selección adecuada de la función ventana será una tarea difícil y está sujeta a la señal a analizar. Existe una dificultad con las distribuciones STFT debido a que no es posible obtener simultáneamente una buena resolución en el dominio del tiempo y de las frecuencias.

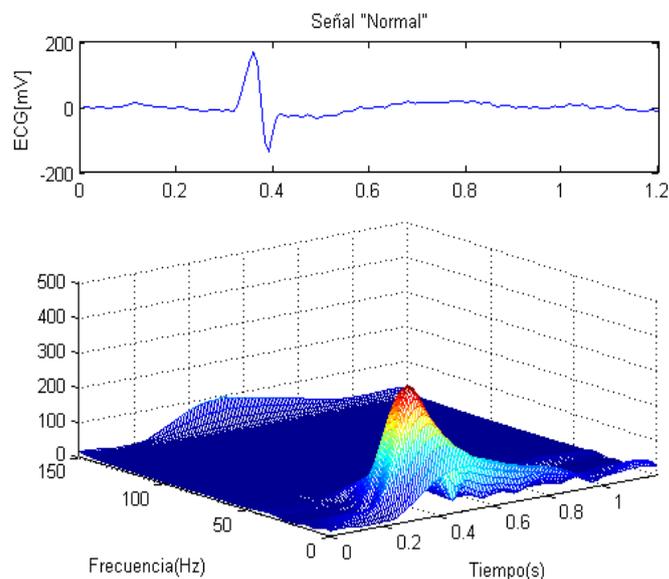


FIGURA 26. EJEMPLO DE DISTRIBUCIÓN DE TRANSFORMADA CORTA DE FOURIER EN TIEMPO Y FRECUENCIA DE LA SEÑAL ECG 'NORMAL'.

Se pueden utilizar otras distribuciones para resolver este inconveniente de la limitación de resolución de la STFT, que se describirán luego.

## Transformada Wavelet

### Aspectos básicos de la transformada Wavelet

La Transformada Wavelet (*WT-Wavelet-Transformation*) nació en los últimos años como una técnica de estudio y diagnóstico de señales no estacionarias complejas. Este método se desarrolló para superar los problemas de resolución de la STFT y de Gabor, haciendo posible una buena representación de una señal tanto en frecuencia como en tiempo de manera simultánea, con lo que se puede definir el intervalo de tiempo en el cual aparecen los componentes espectrales. Ciertamente, son de mucha utilidad para aplicaciones en el análisis señales e imágenes [87], [88].

Básicamente, lo que hace la WT es filtrar una señal en el dominio del tiempo a través de filtros paso bajo y paso alto que elimina algunos componentes de alta o baja frecuencia de la señal. El mismo proceso se realiza para las señales resultantes del proceso de filtrado anterior. Además, se cuenta con un grupo de señales que representan la misma señal, con diferentes bandas de frecuencia. Se aglomeran en una gráfica tridimensional como muestra la figura 27.

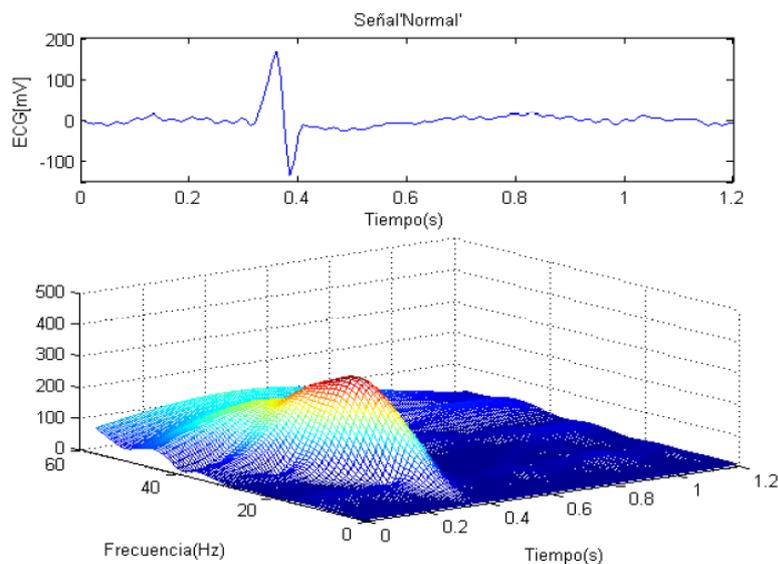


FIGURA 27. EJEMPLO DE DISTRIBUCIÓN DE TRANSFORMADA WAVELET EN TIEMPO Y FRECUENCIA DE LA SEÑAL ECG 'NORMAL'.

Existe el interés de reemplazar la STFT por WT, puesto que la STFT funciona con una resolución fija para todos los tiempos mientras que WT trabaja con una resolución variable. El análisis de WT y STFT se efectúa de forma idéntica, de modo que la señal es reproducida por una función Wavelet de manera similar a la función ventana en la STFT, luego la transformada se calcula separadamente para varios segmentos de la señal en el dominio del tiempo.

La WT se divide en la Transformada Wavelet Continua (CWT-Continuous Wavelet Transform) y la Transformada Wavelet Discreta (DWT-Discrete Wavelet Transform).

La WT continua se fundamenta en la descomposición de una función de entrada usando versiones trasladadas y escaladas de una función wavelet madre, que se define como muestra en la ecuación 52:

$$\psi(b, a) = 1/\sqrt{|a|} \psi((t - b)/a) \quad (52)$$

La descripción matemática de WT continua se presenta en la ecuación 53, que se calcula como el producto interno entre la señal  $x(t)$  y trasladadas y escaladas de la función  $\psi(b, a)$ , donde  $\psi$  es la función de transformación que define la wavelet madre,  $a$  y  $b$  los parámetros de escala y translación respectivamente.

$$C(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t - b}{a}\right) dt \quad (53)$$

En donde  $C(a, b)$  son los Coeficientes wavelet.

### La transformada wavelet de una función Discreta

La Transformada wavelet continua tiene su versión discreta para su implementación digital en la transformada wavelet discreta, como se observa en la ecuación 54.

$$DWT[j, k] = \frac{1}{\sqrt{a_0^k}} \sum_{n \in \mathbb{Z}} x[n] g\left(\frac{k - nb_0 a_0^k}{a_0^k}\right) \quad (54)$$

Donde  $g(t)$  es la wavelet madre,  $k$  es el número de muestra en la señal de entrada y los factores de escalado  $a$  y de translación  $b$  se convierten en funciones discretas del parámetro  $k$  en la expresión  $a = a_0^k$  y  $b = nb_0 a_0^k$ .

### Formas cuadráticas (bilineales):

En 1966 León Cohen [68] trabajando en Mecánica Cuántica, realizó un estudio generalizado de distribuciones de tiempo-frecuencia, que consiste en el desarrollo de un modelo generalizado que todas las distribuciones deberían seguir. Las distribuciones de tiempo-frecuencia del tipo Cohen, son representadas con la ecuación 55 [67]:

$$T_x(t, f) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} e^{j2\pi\theta(u-t)} \phi(\tau, \theta) x\left(u + \frac{\tau}{2}\right) x^*\left(u - \frac{\tau}{2}\right) e^{-j2\pi f\tau} du d\tau d\theta \quad (55)$$

En donde,  $\tau$  y  $\theta$  corresponden a los deslizamientos en tiempo y en frecuencias, respectivamente, de la señal  $x(t)$ , y también  $\phi(\tau, \theta)$  es una función llamada kernel, que determina de forma única las propiedades de cada una de las distribuciones pertenecientes a esta clase [89]. Después, la expresión 55 puede ser reescrita con el kernel  $\phi(\tau, \theta)$  en el dominio de ambigüedad con al siguiente ecuación:

$$T_x(t, f) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} A(\tau, \theta) \phi(\tau, \theta) e^{-j2\pi(t\theta + f\tau)} d\tau d\theta \quad (56)$$

Donde la función de ambigüedad  $A(\tau, \theta)$ , definida como muestra en la ecuación 57.

$$A(\tau, \theta) = \int_{-\infty}^{+\infty} x\left(u + \frac{\tau}{2}\right) x^*\left(u - \frac{\tau}{2}\right) e^{j2\pi\theta u} du \quad (57)$$

Interpretando de una mejor manera la expresión, las RTF de la clase de Cohen como una transformada de Fourier en dos dimensiones del producto entre la función de ambigüedad y el kernel de la representación.

Las características específicas de cada RTF del grupo Cohen dependen de la ventana de kernel aplicada [68]. Sin embargo, la clase cuadrática de distribuciones tiempo-frecuencia sufre de la presencia de términos cruzados [36], [90], las cuales normalmente no existen en el mapa tiempo-frecuencia, y aparecen durante el análisis de las señales. Estos términos de interferencia son los principales inconvenientes en las RTF de tipo Cohen [91].

Si se toma el caso más sencillo de una señal obtenida por la suma de dos señales mono frecuenciales se puede apreciar en la ecuación 58:

$$s(t) = s_1(t) + s_2(t) = e^{j2\pi f_1 t} + e^{j2\pi f_2 t} \quad (58)$$

La RTF de  $s(t)$ , la conforman dos términos correspondientes a las transformadas de las señales mono frecuenciales, sumadas a dos términos cruzados como se observa en la ecuación 59:

$$TFR_x(t, f) = |c_1|^2 TFR_{x_1}(t, f) + |c_2|^2 TFR_{x_2}(t, f) + c_1 c_2^* TFR_{x_{1,2}}(t, f) + c_2 c_1^* TFR_{x_{2,1}}(t, f) \quad (59)$$

Se puede ver que los términos cruzados creados en la representación, no poseen ningún sentido, lo que perjudica el correcto análisis de la señal.

Para una señal que incluye  $N$  elementos frecuenciales, su representación tiempo-frecuencia va a estar formada por  $N$  términos de señal más  $N(N-1)/2$  términos cruzados, por lo que su número aumenta de forma cuadrática con el número de componentes, motivo por el cual se utilizan las llamadas funciones de “kernel” que disminuyan los términos cruzados.

### Distribución de Wigner-Ville

La distribución de (WVD-*Wigner-Ville Distribution*) [92] es una de las representaciones más utilizadas para el análisis tiempo-frecuencia.

Para calcular la WVD se reemplaza el kernel  $\phi(\theta, \tau) = 1$  en ecuación 56, y al simplificar la formula , se obtiene como se puede observar en la ecuación 60 [93].

$$WVD(t, f) = \int_{-\infty}^{+\infty} x^* \left( t - \frac{1}{2} \right) x \left( t + \frac{1}{2} \right) e^{-j2\pi\tau} d\tau \quad (60)$$

Siguiendo la ecuación (56), se observa que la WVD y la función de ambigüedad corresponden a un par de transformadas de Fourier tal como se puede observar en la fórmula 61:

$$WVD(t, f) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} A(\tau, \theta) e^{-j2\pi(t\theta + f\tau)} d\tau d\theta \quad (61)$$

### Limitaciones de la wigner-ville:

Si se aplica la WVD a la ventana de tiempo de ECG sin aplicar la transformada de Hilbert antes de efectuar la descomposición en tiempo-frecuencia, la figura 28 muestra la simetría del diagrama debido a las frecuencias negativas y las positivas.

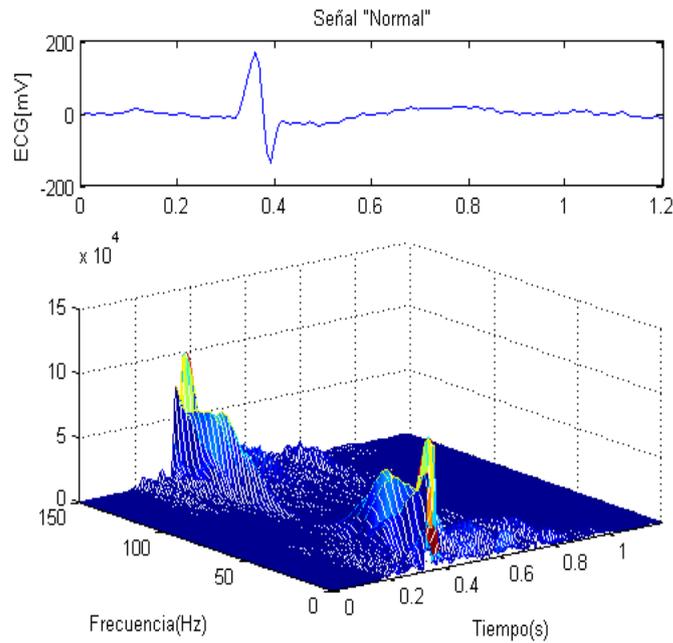


FIGURA 28. DISTRIBUCIÓN DE WVD DE LA SEÑAL 'NORMAL' PROCESADAS DIRECTAMENTE SIN USAR LA TRANSFORMADA DE HILBERT.

En el segundo caso, se calcula primero la señal analítica mediante la transformada de Hilbert, y a partir de dicha señal analítica obtenida se procesa cada matriz usando WVD como muestra la figura 29.

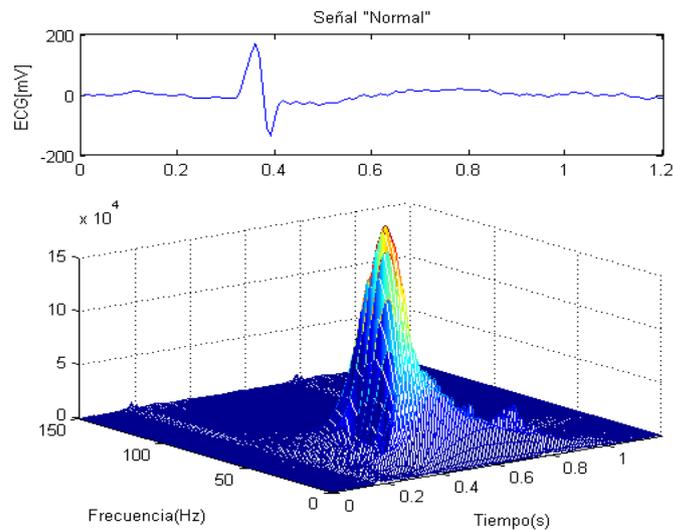


FIGURA 29. DISTRIBUCIÓN DE WV DE LA SEÑAL ANALÍTICA 'NORMAL' USANDO LA TRANSFORMADA HILBERT.

Se puede apreciar cómo la eliminación de las frecuencias negativas en la distribución tiempo-frecuencia disminuye los términos cruzados, apareciendo un diagrama mucho más limpio.

Con el fin de eliminar términos cruzados, existen variantes de la RTF de ‘Pseudo-’ y ‘Suavizada’: ‘Pseudo-’ se podría decir que esta representación consiste en una versión enventanada de la anterior que es equivalente a un suavizado únicamente en dirección de la frecuencia, mientras que en la suavizada permite controlar de forma independiente el suavizado en el eje temporal y en el frecuencial, en la figura 30 una representación de la Pseudo Wigner-Ville (PWV).

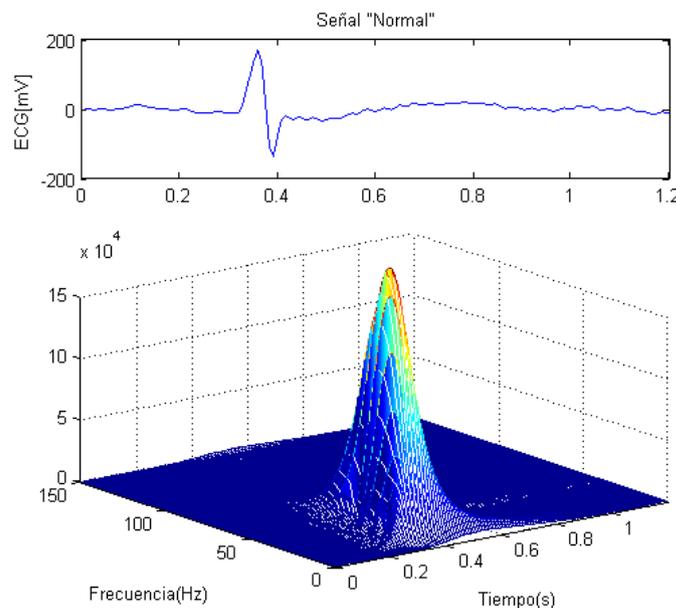


FIGURA 30. DISTRIBUCIÓN DE PWV DE LA SEÑAL ANALÍTICA DE ECG ‘NORMAL’.

En comparación con la WVD, se han disminuido los artefactos e interferencias que la WVD introducía, lo que permite visualizar espectros más claros y con una mayor concentración energética de los componentes reales la señales del ECG.

La distribución de (PWVD-*Pseudo-Wigner-Ville Distribution*) es determinada como una WVD en tiempo corto, la cual se multiplica por una función de ventana de  $h(t)$ , donde se disminuyen los términos cruzados empleando dichas ventanas suavizadas en el dominio del tiempo antes de calcular la WVD. La descripción matemática de PWV se define como [94], [95] como muestra en la ecuación 62:

$$PWVD(t, \omega) = \int_{-\infty}^{+\infty} h(\tau)x\left(u + \frac{\tau}{2}\right)x^*\left(u - \frac{\tau}{2}\right)e^{-j\omega\tau}d\tau du \quad (62)$$

Donde el *Kernel* de esta distribución como indica la ecuación 63:

$$\phi(\theta, \tau) = g\left(\frac{\tau}{2}\right)g^*\left(-\frac{\tau}{2}\right) \quad (63)$$

La Distribución Suavizada (SPWVD-*Smoothed Pseudo Wigner-Ville Distribution*) [86], [93], se la conoce como una WVD en tiempo corto y suavizado, aplicando dos ventanas; una ventana de suavizado en el tiempo  $h(t)$  y una ventana de análisis  $g(t)$  como se observa en la ecuación 64.

$$SPWVD(t, \omega) = \int_{-\infty}^{+\infty} h(\tau)g(u - t)x\left(u + \frac{\tau}{2}\right)x^*\left(u - \frac{\tau}{2}\right)e^{-j\omega\tau}d\tau du \quad (64)$$

El *kernel* es:

$$\phi(\theta, \tau) = S(\theta)g_1(\tau) \quad (65)$$

Donde:

$$g_1(\tau) = g\left(\frac{\tau}{2}\right)g^*\left(-\frac{\tau}{2}\right) \quad (66)$$

$S(\theta)$  Es la transformada de Fourier de  $h(t)$ .

Así, la frecuencia y tiempo se pueden controlar de forma independiente, escogiendo la longitud de las ventanas  $h(t)$  y  $g(t)$ , respectivamente: entre más larga sea  $g(t)$  se origina un menor suavizado en la frecuencia, de modo que una  $h(t)$  más larga producirá más suavizado en tiempo. La figura 31 muestra el resultado de utilizar esta distribución a la misma señal que en los casos anteriores.

También existen otros núcleos y representaciones originadas de la representación de Wigner-Ville, como las representaciones de Born-Jordan y Choi-Williams.

Alfredo [92] describe la presencia de los términos interferentes en la WVD mientras que éstos han sido eliminados en la CWD mediante kernel exponencial de la CWD que ha demostrado que tiene un mejor comportamiento que la WVD, y se demuestra que esta técnica es capaz de presentar una buena resolución con relación al cambio de frecuencia con el tiempo de las componentes de las diferentes señales.

De igual manera, se ha demostrado que la distribución de (DBessel-Distribution de Bessel) basada en la función de Bessel de ECG reduce la negatividad al disminuir la magnitud de los términos interferentes.

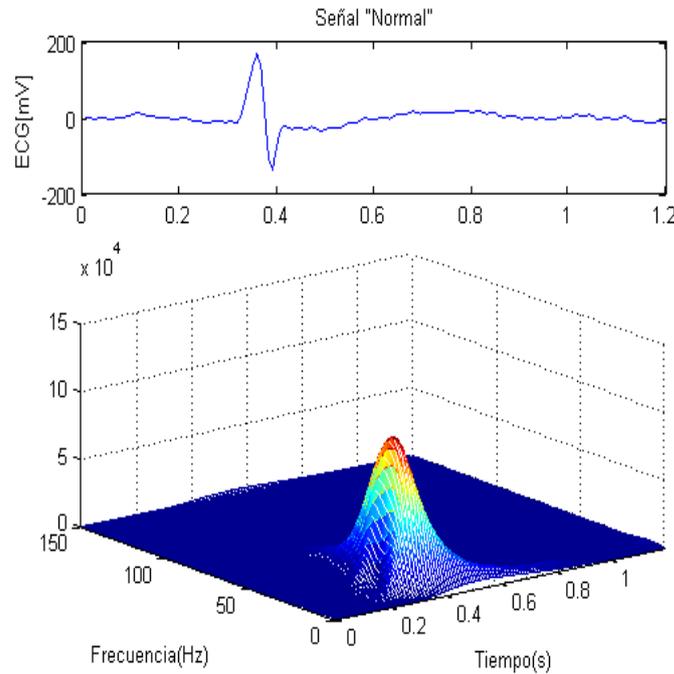


FIGURA 31. DISTRIBUCIÓN DE SPWVD DE LA SEÑAL ANALÍTICA DE ECG 'NORMAL'.

### Distribución Choi-Williams

La distribución de (CWD-*Choi-Williams Distribution*) es una WVD suavizada que posee una gran cantidad de propiedades matemáticas importantes en las distribuciones tiempo-frecuencia. Ésta utiliza la función de *kernel* que minimiza los términos cruzados aplicando funciones exponenciales [96].

El *kernel* de la CWD. Está dado por la ecuación 67 [97]:

$$\phi(\theta, \tau) = e^{-\frac{(2\pi\theta\tau)^2}{\sigma}} \quad (67)$$

Donde  $\sigma$  es un parámetro positivo que domina la concentración del *kernel*

La siguiente ecuación de la distribución resultante:

$$CWD(t, \omega) = \int_{-\infty}^{+\infty} \frac{\sigma}{|\tau|^2} e^{-\frac{2\tau\sigma^2(u-t)^2}{\tau^2}} x\left(u + \frac{\tau}{2}\right) x^*\left(u - \frac{\tau}{2}\right) e^{-j\omega\tau} d\tau du \quad (68)$$

El espectro de la señal ECG creada mediante CDW se muestra en la figura 32.

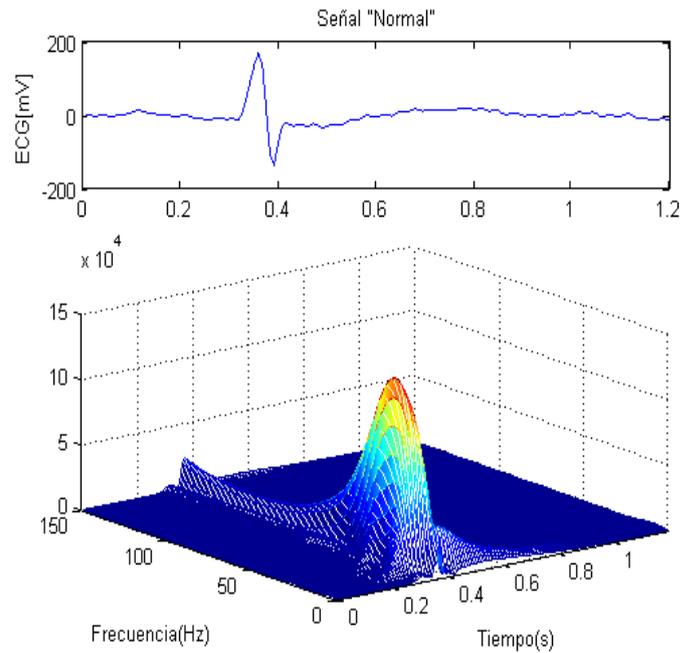


FIGURA 32. REPRESENTACIÓN DE TIEMPO-FRECUENCIA DE SEÑAL ANALÍTICA DE ECG ‘NORMAL’ MEDIANTE LA APLICACIÓN DE LA TÉCNICA DE CHOI-WILLIAMS.

En la misma figura se observa que la representación de tiempo-frecuencia de Choi-Williams, puede reducir considerablemente el índice de términos de interferencia.

La distribución de (BJD-*Born-Jordan Distribution*), se presenta en la siguiente expresión [93], [67], [75]:

$$BJ(t, \omega) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \frac{1}{|\tau|} \int_{t-\frac{|\tau|}{2}}^{t+\frac{|\tau|}{2}} \left(u + \frac{\tau}{2}\right) x^* \left(u - \frac{\tau}{2}\right) e^{-j\omega\tau} d\tau du \quad (69)$$

El *kernel* cumple la condición:

$$\phi(\theta, \tau) = \frac{\text{sen}(\pi\theta\tau)}{\pi\theta\tau} \quad (70)$$

La figura 33 muestra las representaciones de tiempo-frecuencia obtenidas por el análisis de las señales ECG por medio de la técnica de Born-Jordan aplicando de la ecuación 69.

En la interpretación de la representación de tiempo-frecuencia de Born-Jordan en la figura 33 se demuestra que esta técnica es capaz de presentar una buena resolución con relación al cambio de frecuencia con el tiempo de las componentes de las diferentes señales.

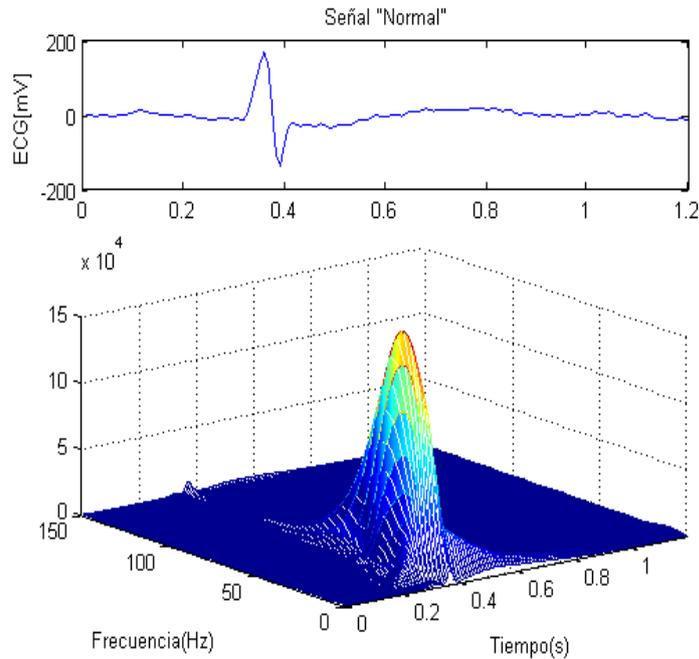


FIGURA 33. REPRESENTACIÓN DE TIEMPO-FRECUENCIA DE LA SEÑAL ANALÍTICA DE ECG 'NORMAL' MEDIANTE LA DISTRIBUCIÓN DE BORN-JORDAN.

La distribución de (DBessel-*Distribution de Bessel*) basada en la función de Bessel de primer orden para un señal  $x(t)$ , pudiéndose determinar en la ecuación 71 [98], [31]:

$$DB_x(t, f) = \int_{-\infty}^{+\infty} h(\tau) R_x(t, \tau) e^{-j2\pi f\tau} d\tau \quad (71)$$

Donde,

$$R_x(t, \tau) = \int_{t-|\tau|}^{t+|\tau|} \frac{2g(s)}{\pi|\tau|} \sqrt{1 - \left(\frac{s-t}{\tau}\right)^2} x\left(s + \frac{\tau}{2}\right) x^*\left(s - \frac{\tau}{2}\right) ds \quad (72)$$

Donde,  $h(\tau)$  y  $g(s)$  representan ventanas suavizadas en el tiempo y frecuencias. Esta técnica se introdujo para reducir los términos de interferencia a través la función de Bessel ver la figura 34.

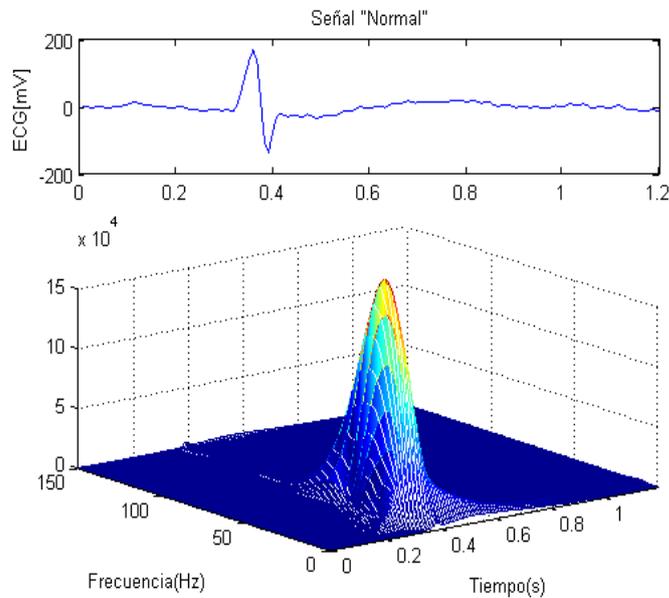


FIGURA 34. REPRESENTACIÓN DE TIEMPO-FRECUENCIA DE LA SEÑAL ANALÍTICA DE ECG ‘NORMAL’ MEDIANTE LA DISTRIBUCIÓN DE BESSEL.

### 3.3.3 Extracción de la información de RTF e IRTF

En general, la extracción de la información es la etapa encargada de transformar a otra representación el segmento temporal de la señal del ECG a analizar, con el fin de alcanzar informaciones adecuadas para la detección de diferentes patologías. Es la etapa principal del sistema de clasificación, sin embargo, la no estacionalidad de la señal ECG no hace fácil la extracción de la información apropiada, por lo que es imprescindible seleccionar un conjunto de datos apropiado para alimentar el algoritmo de clasificación. Entre las estrategias de extracción de la información se encuentran los métodos basados en: Parámetros extraídos directamente de la señal ECG, como pueden ser amplitud y áreas [99], u otros métodos como las transformadas de distribuciones de tiempo-frecuencia [100] y las transformadas de wavelet [101].

Como se ha descrito anteriormente en la sección 3.3.1, luego del cálculo de las  $V_t$ , de longitud 150 muestras (1,2 s) prosigue la segunda etapa del procesado de la señal ECG a través de la transformada de Hilbert generando cada una la RTF lo cual se registra en una Matriz de Datos MD'. Y luego se la convirtió en IRTF de tamaño 45x150, las cuales fueron almacenadas en una Matriz de Datos MD'' (no reducida).

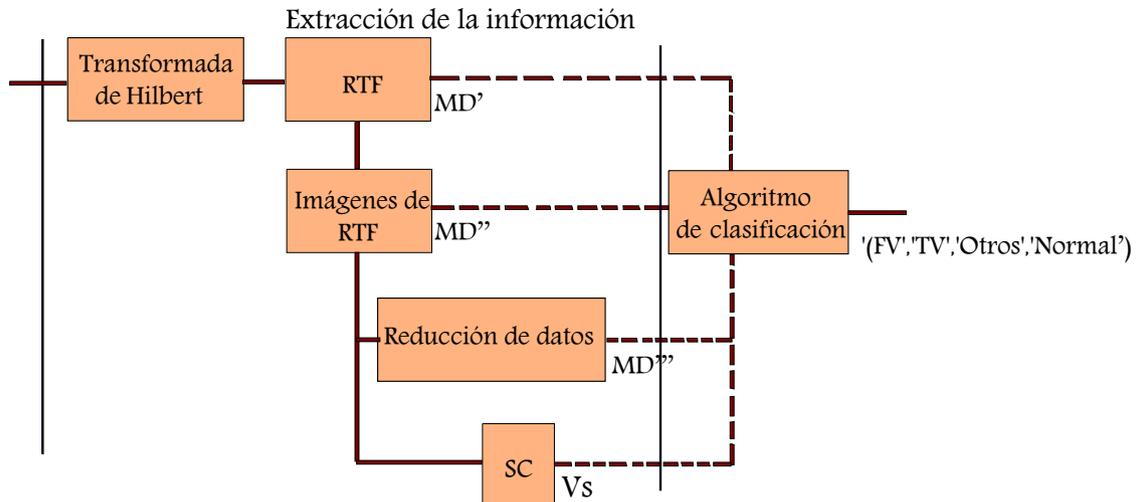


FIGURA 35. DIAGRAMA DE LA ETAPA DE EXTRACCIÓN REALIZADA PARA LA DETECCIÓN DE FIBRILACIÓN VENTRICULAR. TRAS LA RTF, SE MUESTRAN LAS DOS OPCIONES DE IMAGEN EXTRAÍDA, SIN REDUCCIÓN DE DATOS, CON DIMENSIONALIDAD REDUCIDA Y ADEMÁS LA SELECCIÓN DE CARACTERÍSTICAS.

Se realizó la disminución de dimensionalidad de los datos obtenidos anteriormente en dos formas: Reducción del tamaño de IRTF y Selección de Características (SC) y posteriormente se registran en la matriz  $MD'''$  y el vector  $V_{sc}$  respectivamente. Se usan las  $MD = (MD', MD'', MD''', V_{sc})$  obtenidas anteriormente mediante cada técnica, como matriz de entrada para el algoritmo de clasificación (figura 35).

### 3.3.3.1 Extracción de la información mediante RTF

En primer lugar, se efectúa la transformada de Hilbert de cada  $V_t$  obteniendo la señal analítica, de forma que se cancela el espectro de dicha señal de todos los componentes con frecuencias negativas, que podría crear términos cruzados con frecuencias positivas.

En segundo lugar, una vez reducidos los componentes de frecuencia negativa, se aplique la RTF de cada  $V_t$ , se cancelan las contribuciones en frecuencias por encima de 45Hz, con lo que se eliminan tanto la interferencia de red (50Hz, 60 Hz) como el electromiograma (EMG). Esto resulta útil dado que la señal de interés se encuentra en valores por debajo de la frecuencia de 45 Hz, con ello, se obtiene una Matriz de Datos ( $MD'$ ) de la RTF de tamaño 45x150 como muestra la figura 36. Cada matriz  $MD'$  de RTF se usa posteriormente en el entrenamiento y prueba de los algoritmos de clasificación.

Se puede ver en la primera línea de la figura 36 que las distribuciones de energía difieren claramente en el dominio tiempo-frecuencia para cada clase definida. En el caso de la señal ‘Normal’, la energía se localiza en el tiempo, principalmente debido al complejo QRS, y presenta una amplia gama de frecuencias.

En el caso de ‘TV’, la energía se distribuye más regularmente a lo largo del segmento de tiempo, con un patrón repetido.

Para la señal ‘FV’, la energía se reparte irregularmente en la distribución a lo largo del eje de tiempo y frecuencia, y ningún patrón específico está presente.

Puesto que la clase ‘Otros’ incluye varias morfologías, las distribuciones de energía y sus características son diversas.

### 3.3.3.2 Extracción de la información mediante IRTF

Una vez obtenida la MD’ de RTF de cada ventana  $V_t$ , se convierte dicha matriz de datos RTF a una imagen IRTF $_{L_f \times L_t}$  de tamaño  $L_f \times L_t$  pixeles con  $L_f = 45$  y  $L_t = 150$ , convirtiendo los niveles de energía de la señal dentro del rango que va desde 0 a 255. Estos valores se corresponderán con distintos niveles de gris en una imagen tal y como se muestra en la segunda línea de la figura 36. Cada imagen se almacena en una Matriz de Datos (MD’’) de tamaño  $L_f \times L_t$ .

De este modo, la RTF y la IRTF que resulta del análisis de tiempo-frecuencia contiene todos los datos necesarios, tanto temporales como espectrales, de la señal del ECG en cada uno de los tipos de señales a clasificar.

Tratar la RTF como imagen posee la ventaja de poder aplicar técnicas de clasificación comúnmente empleadas en tratamiento de imágenes.

Es un objetivo de este trabajo analizar la capacidad de clasificación de una señal temporal mediante su imagen tiempo-frecuencia.

Dado a que el tamaño de la MD’’) de IRTF obtenida anteriormente para aplicar al clasificador es muy grande  $L_f L_t$  ( $45 \times 150 = 6750$ ), implicando una elevada carga computacional, se utilizan técnicas que reduzcan la dimensión de cada MD’).

Algunas de las técnicas de reducción de dimensionalidad más utilizadas son: interpolación por vecino más próximo (KNN), interpolación bilineal e interpolación bicúbica [102]. (PCA-

principle component analysis) y (LDA-linear discriminant analysis) [103]. (MDS-Multidimensional Scaling) [104], etc.

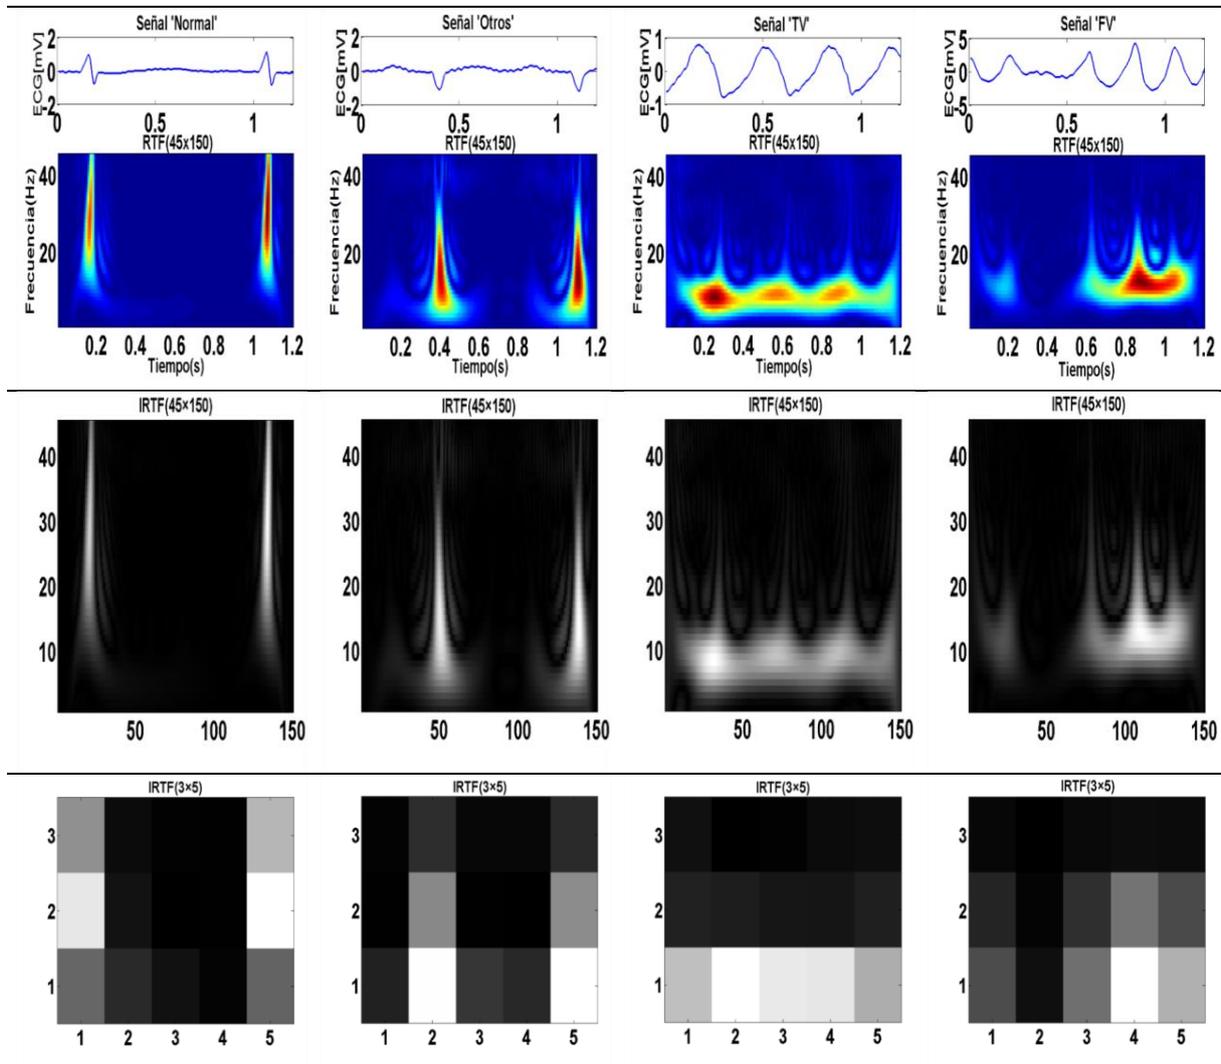


FIGURA 36. DE ARRIBA A ABAJO: LAS VENTANAS DE SEÑAL ORIGINALES Y SU CORRESPONDIENTE RTF E IRTF DE TAMAÑO 45X150 JUNTO CON LA IRTF DE TAMAÑO REDUCIDO 3X5 PARA SEÑALES DE TIPO 'NORMAL', 'OTROS', 'TV' Y 'FV' (EN COLUMNAS).

### Las técnicas empleadas en este trabajo son:

Un algoritmo desarrollado (Media de la Intensidad de los Píxeles (MIP) ), interpolación por KNN, interpolación bilineal e interpolación bicúbica [105], además un análisis de la selección de características (SC) [106].

### 3.3.3.2.1 Media de la intensidad de los píxeles

La técnica de reducción de datos que se desarrolló en este trabajo es relativamente simple en comparación con otras técnicas. Su objetivo principal es la disminución de  $IRTF_{L_f \times L_t}$  de tamaño  $L_f \times L_t$  píxeles a  $IRTF_{L_a \times L_b}$  de tamaño  $L_a \times L_b$  píxeles.

Primer paso: sobre la  $IRTF_{L_f \times L_t}$  se efectúa una división de la imagen en rectángulos  $R_{nm}$  de tamaño  $K \times J$  píxeles según la ecuación (73).

$$IRTF_{L_f \times L_t} = \sum_n^{L_a} \sum_m^{L_b} R_{nm}; [n = 1, \dots, L_a; m = 1, \dots, L_b] \quad (73)$$

Donde  $L_a = \frac{L_f}{K}$ ,  $L_b = \frac{L_t}{J}$ .

El punto  $(n, m)$  para localizar el rectángulo  $R_{nm}$  en  $IRTF_{L_a \times L_b}$ .

Se elige  $K = 15$ ,  $J = 30$  como el promedio mínimo de elección por lo cual no se pierde la información.

Segundo paso: consiste en calcular la media de la intensidad de los píxeles de cada rectángulo  $R_{nm}$  utilizando la ecuación 74, donde,  $I\_MediaPíxeles_{nm}(R_{nm})$  es la intensidad media de los píxeles en el rectángulo  $R_{nm}$  y  $K \times J$  es el tamaño del rectángulo ( $R_{nm}$ ).

$$I\_MediaPíxeles_{nm}(R_{nm}) = \frac{\sum_{kj} I\_Pixel_{kj}(R_{nm})}{K \times J} \quad (74)$$

También se tiene  $I\_Pixel_{kj}(R_{nm})$  que es la intensidad del  $pixel_{kj}$  en el rectángulo  $R_{nm}$  y  $k = 1, \dots, K$ ;  $j = 1, \dots, J$ .

Este proceso se repite para todos los rectángulos de la imagen, obteniendo como resultado un imagen  $IRTF_{L_a \times L_b}$  de tamaño  $L_a \times L_b$  con ( $L_a = \frac{L_f}{K} = 3$ ;  $L_b = \frac{L_t}{J} = 5$ ), representativo de esos datos, como se muestra en la figura 36. Igual como en los caso de RTF,  $IRTF$  no reducida, cada  $IRTF$  reducida se transforma a una Matriz de Datos (MD''') de tamaño  $(3 \times 5)$  para luego ser usadas como entrada de clasificador.

### 3.3.3.2.2 Interpolación

Además de la técnica de MIP, se ha usado la interpolación, la cual disminuye el tamaño de una imagen inicial mediante un algoritmo específico [105].

Las interpolaciones en imágenes más importantes son:

- Interpolación vecino más cercano KNN: es uno de los algoritmos más usados por su simplicidad. Esta técnica tiene en cuenta el pixel más cercano de los cuatro píxeles que rodean al pixel interpolado.
- Interpolación Bilineal: considera el promedio de los cuatro píxeles próximos al pixel interpolado.
- Interpolación Bicúbica: es considerado estándar (promedia 16 píxeles adyacentes al pixel interpolado).

### 3.3.3.2.3 Selección de características

Es una parte importante del aprendizaje automático. Se trata de reducir la dimensionalidad de los conjuntos de características usados como entrada del clasificador, aportando varias ventajas como la disminución de los tiempos de entrenamiento y coste computacional. También permite seleccionar un conjunto de características de información útil y mejor calidad de clasificación, permitiendo eliminar características de información redundante.

Existe bibliografía importante sobre trabajos realizados anteriormente donde se han utilizado diferentes técnicas para la selección de las mejores características, entre ellas el algoritmo genético (AG) [107], la técnica de selección secuencial hacia adelante (SFS-*sequential forward selection*) y selección secuencial hacia atrás (SBS-*sequential backward selection*) [108].

Una vez realizado el proceso de selección de características mediante SFS bidireccional a partir de MD'' de IRTF no reducida, se ha alcanzado un subconjunto reducido Vsc del espacio de características original. Este subconjunto reducido se usa como entrada del clasificador, que va a tomar estas características y las va a asignar a una de las clases de patología.

## 3.4 Clasificación

Una vez obtenida la información adecuada mediante la RTF, IRTF, IRTF de tamaño reducido y SC, generando el conjunto de matrices de datos MD de tipos (MD', MD'', MD''', Vsc) de

cada ventana  $V_t$ , este trabajo plantea que dichas MD se empleen como entrada al clasificador (ver la figura 35) para uso posterior en el entrenamiento y prueba de los algoritmos de clasificación, con el fin de detección de los diferentes tipos de patología cardiaca.

Los capítulos 4 y 5 describen pormenorizadamente el proceso seguido, los resultados obtenidos en función del tipo de pre-procesado, conjunto de datos de entrada al clasificador, y tipo de clasificador empleado.

*En este capítulo se presentan los resultados de la implementación de la metodología descrita en el capítulo 3. Primero se describen los algoritmos de clasificación existentes en la literatura para su aplicación sobre la detección FV. Segundo se presenta el procedimiento de clasificación por medio del entrenamiento y prueba. Tercero se presentan las estrategias para analizar los resultados de la detección FV mediante los algoritmos de clasificación individual, donde se calcula sensibilidad, especificidad y exactitud para las clases 'Normal', 'Otros', 'TV' y 'FV'. Además, se analiza el tiempo de ejecución medio de todo el proceso de cálculo obtenido para cada ventana  $V_t$  de la señal ECG, con el fin de comparar e identificar la estrategia adecuada con la cual se puede obtener un mejor desempeño en la clasificación, en tiempo real.*

## Capítulo 4. Algoritmos de clasificación para la detección de FV

En general, se usan técnicas de minería de datos (del inglés, *data mining*) para el análisis de datos en cuanto a su dimensión, guardados en grandes cantidades y en tiempo real. Existe otro campo de la ciencia de la computación llamado aprendizaje automático (*machine learning*) que asocia a este proceso de minería de datos, que trata de crear programas con la capacidad de impartir comportamientos por medio de una información no estructurada.

En esta investigación se han utilizado algoritmos de aprendizaje automático con una visión conveniente para mejorar la eficiencia de detección de FV. Así como se explicó en el capítulo anterior, en la etapa de clasificación se toman matrices MD que alimentan a los algoritmos de aprendizaje automático. Luego, se calcula la función de predicción a partir del conjunto de entrenamiento, para posteriormente ser aplicado al conjunto de prueba.

### 4.1 Aprendizaje automático

Generalmente permite asignar a los computadores la capacidad de aprender patrones usados, para luego resolver problemas nuevos.

Existen dos grandes grupos de técnicas para este aprendizaje: aprendizaje supervisado y aprendizaje no supervisado (ver la figura 37). Las primeras están en correspondencia con las tareas de detección de clasificación y regresión. Las segundas con las tareas de agrupamientos y correlaciones. En este trabajo sólo hablaremos del aprendizaje supervisado.

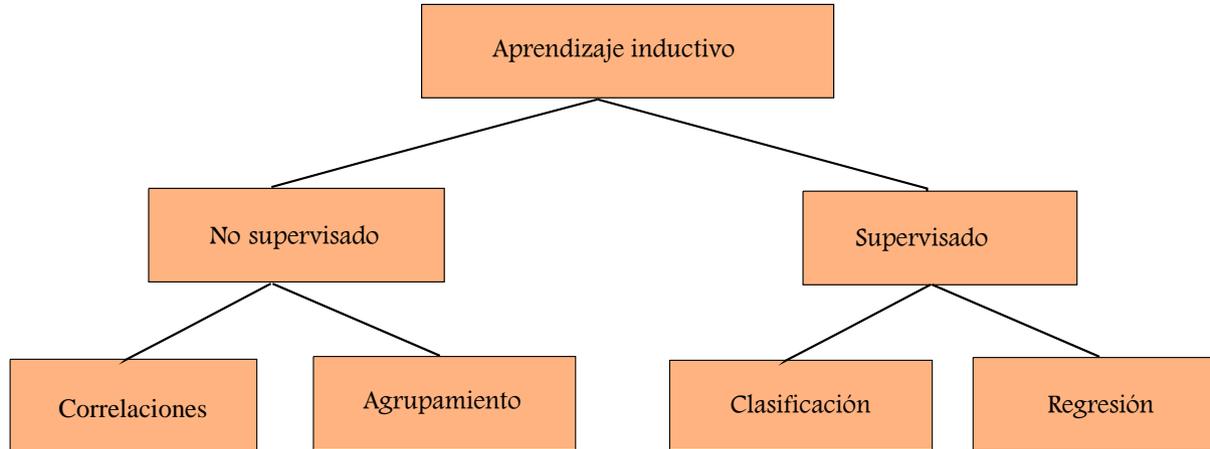


FIGURA 37. TÉCNICAS DE APRENDIZAJE AUTOMÁTICO.

Los algoritmos de aprendizaje supervisado [109] son usados como técnica de aprendizaje de patrones y disminución de la dimensionalidad. Requieren un etiquetado de cada uno de los patrones de entrada. El objetivo de los algoritmos o de aprendizaje supervisado es construir una función a partir de datos de aprendizaje y transformarlos en salidas deseadas.

Los algoritmos de aprendizaje no supervisado [110] son unas técnicas de aprendizaje automático en el cual un modelo es ajustado a las observaciones. Se diferencian del aprendizaje supervisado en que no hay un aprendizaje a priori. El aprendizaje no supervisado frecuentemente trata los datos de entrada como un conjunto de datos aleatorios. No se dispone de las salidas esperadas de los datos y se busca estructura en los datos de entrada.

Existe mucha bibliografía sobre los algoritmos de aprendizaje para su aplicación en la bioseñales, entre estos se encuentran árboles de decisión [111], redes neuronales artificiales y máquinas de soporte vectorial [62], aprendizaje basado en Naïve Bayes [112][113]. Análisis discriminante lineal [114], clasificador K-vecinos más cercanos (KNN) [115][116], máquinas de aprendizaje extremas (ELM-*Extreme Learning Machines*) [117], etc.

## 4.2 Métodos de Clasificación

En este trabajo se utilizarán varios clasificadores en cada una de las pruebas para evaluar el rendimiento de los algoritmos de detección de FV.

A continuación sólo se presentan los modelos matemáticos generales de cada algoritmo, sin detalles.

### 4.2.1 Clasificador de K vecinos más cercanos

El algoritmo K vecinos más cercanos (KNN, por sus siglas en inglés) es un método simple, pero a la vez de alto rendimiento en clasificación.

Ha sido usado en diversas aplicaciones: para la detección y clasificación de las etapas de sueño usando ECG [118] y para, en combinación con AdaBoost Bootstrap distinguir entre periodos con y sin episodios de apnea [119]. También se ha usado KNN para diagnosticar enfermedades del corazón de forma automática [120].

El algoritmo KNN [121] clasifica un nuevo vector aplicando un conjunto de entrenamiento sin necesidad de aprender parámetros, a diferencia de otros algoritmos que aplicando un conjunto de entrenamiento aprende algunos parámetros y luego utilizando estos últimos clasifican un nuevo vector. El algoritmo KNN es el siguiente:

Un conjunto de entrenamiento  $D = \{(V_i, \text{etiqueta}_i) \text{ con } i = 1, \dots, N\}$  donde  $N$  número vectores de características}. Cada  $V_i$  de los cuales está caracterizado por  $n$  variables atributos  $\{V_i = (p_{i1}, \dots, p_{in})\}$  correspondiente a una etiqueta  $i \in C = \{\text{etiqueta}_i \text{ con } i = 1, \dots, N\}$ . En los cuales están agrupados en  $m$  clases  $\{\text{etiqueta}_i \in \{\text{clase}^1, \dots, \text{clase}^m\}\}$ , como se observa en la tabla 1.

Para definir la clase del nuevo vector  $V = (p_j, j \in \{1..n\})$  que no pertenece al conjunto  $D$  que se ha introducido en la entrada de KNN, en primera instancia se fijan las distancias de todos los casos que fueron clasificados con respecto al nuevo caso  $V$ , que se busca clasificar.

Luego, el algoritmo KNN busca los  $K$  vecinos más cercanos al  $V$ , y posteriormente hace una valoración de las clases a las que están integradas estos vectores vecinos. Esta valoración se basa en comparar las distancias que existen entre las clases.

TABLA 1. CONJUNTO DE ENTRENAMIENTO.

	P <sub>1</sub>	...	P <sub>j</sub>	...	P <sub>n</sub>	C
V <sub>1</sub>	p <sub>11</sub>	...	p <sub>1j</sub>	...	p <sub>1n</sub>	etiqueta <sub>1</sub>
...	...		...		...	...
V <sub>i</sub>	p <sub>i1</sub>	...	p <sub>ij</sub>	...	p <sub>in</sub>	etiqueta <sub>i</sub>
...	...		...		...	...
V <sub>N</sub>	p <sub>N1</sub>	...	p <sub>Nj</sub>	...	p <sub>Nn</sub>	etiqueta <sub>n</sub>

Los algoritmos usados en esta valoración pueden ser varios: distancia Mahalanobis, distancias usando la función delta, distancia del coseno, distancia euclídea, etc.

La distancia euclídea es una de las más empleadas, se calcula a partir de una generalización del teorema de Pitágoras como se puede ver en la ecuación 75.

$$d(V, V_i) = \sqrt{\sum_{j=1}^n (p_{ij} - p_j)^2} \quad (75)$$

Finalmente, una vez seleccionados los  $K$  casos ya clasificados en  $D$  más cercanos al nuevo caso  $V$ , se le asignará la clase de  $C$  más frecuente de entre los  $K$  integrados en  $D$ .

#### 4.2.2 Máquinas de vectores de soporte

Los algoritmos de aprendizaje Máquina de vector de soporte (*SVM-Support Vector Machine*) fueron creados por Vladimir Vapnik [122], es un sistema para entrenar máquinas de aprendizaje lineal eficientemente tanto para regresión como para clasificación.

SVM ha sido muy empleado para la detección y clasificación de arritmias cardíacas, se usa SVM para la discriminación entre la fibrilación ventricular y taquicardia ventricular [123]. También se utilizó para la detección de QRS [124], la detección de la onda T y la onda P en ECG de 12 derivaciones [125] y en [62] se usa el método (*SSVM-Smooth Support Vector Machine*), para la detección FV [126].

#### Clasificación lineal para problemas linealmente separables

SVM para la clasificación lineal se basa en hiperplanos que dividen los datos de entrenamiento en diferentes subgrupos con la misma clase. Se tiene un hiperplano de separación óptima (margen máximo) para el entrenamiento.

Los vectores de  $x_i$  en dos clases  $y_i$  con  $i = 1 \dots N$ , donde  $x_i \in \mathbb{R}$ ,  $y_i \in \{-1, 1\}$  se basan en la siguiente ecuación 76:

$$\begin{cases} w \cdot x_i + b \geq 1, & y_i = 1 \\ w \cdot x_i + b \leq -1, & y_i = -1 \end{cases} \quad (76)$$

Sujeto a:

$$y_i(w \cdot x_i + b) \geq 1, i = 1, \dots, N \quad (77)$$

Donde  $w$  es el vector de pesos y  $b$  el bias.

$$\text{Min}_{w,b} \frac{1}{2} \|w\|^2 \quad (78)$$

Donde  $\frac{1}{2} \|w\|^2$  es la función a disminuir con relación al vector  $w$  y el valor  $b$ , que clasifica el hiperplano que divide las clases con mayor distancia (margen máximo), utilizando la técnica de los multiplicadores de Lagrange.

### Clasificación lineal para problemas linealmente no separables

Se considera el caso en que no existe un hiperplano separador, por lo tanto, no es posible satisfacer todas las restricciones descritas en la ecuación (76).

Se introduce un conjunto de variables  $\xi_i$ ,  $i = 1, \dots, m$ . Donde SVM soluciona el siguiente problema de optimización:

$$\text{Min}_{w,b,\xi} \frac{1}{2} \|w\|^2 + C \sum_a^m \xi_i \quad (79)$$

Sujeto a

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i, \xi_i \geq 0, i = 1, \dots, N \quad (80)$$

### Clasificación no lineal

En este caso en el cual la función de decisión no es lineal con los datos, se emplea la transformación de *Kernel*  $\phi$  que proyecta la información a un espacio de características de mayor dimensión, el cual amplía la capacidad computacional de las máquinas de aprendizaje lineal, al mapear el espacio de entradas  $x \in \mathbb{R}$  a un nuevo espacio de características [127].

$$x = \{x_1, x_2, \dots, x_n\} \xrightarrow{\phi} \phi(x) = \{\phi(x)_1, \phi(x)_2, \dots, \phi(x)_n\} \quad (81)$$

### 4.2.3 Agregación bootstrap o bagging

La agregación Bootstrap, también conocida por Bagging, fue aplicado por Breiman [128] para clasificación y regresión. Se construye combinando la salida de diferentes clasificadores con el fin de crear uno más potente. Diseñado para mejorar el rendimiento en la estabilidad y precisión de los algoritmos de aprendizaje automático, en general árboles de decisión, y redes neuronales. Se pueden utilizar tanto en problemas de 2 clases como a aquellos multiclase.

El algoritmo Bagging ha sido usado en diversas aplicaciones: En [129] usaron el algoritmo Bagging para detectar diferentes patologías cardiacas.

Dado un conjunto de entrenamiento  $D = \{(x_1, y_1), \dots (x_n, y_n)\}$  donde  $x_i \in R, y_i \in \{-1, 1\}$ , se obtienen  $m$  nuevos conjuntos de entrenamiento  $D_b$  aleatorios, de tamaño  $n$ , donde  $D_b = \{(x_1^b, y_1^b), \dots (x_n^b, y_n^b)\}$  donde  $b=1, 2, \dots, m$ , mediante la extracción aleatoria con reemplazamiento mediante el mismo número de elementos que el conjunto original  $D$ . Por consiguiente, algunos elementos del conjunto inicial pueden aparecer repetidos en los nuevos conjuntos creados.

Mediante cada conjunto de entrenamiento  $D_b$  se elabora un clasificador básico  $C_b(x)$ . Una vez construidos los  $m$  clasificadores se combinan empleando el voto mayoritario en la regla de decisión final (en caso de una clasificación) o por la media de ellas (en caso de una regresión).

### 4.2.4 Regresión logística

Regresión logística es una de las técnicas de análisis de datos más populares en clasificación, pertenece a la categoría de aprendizaje supervisado[130].

La regresión logística asocia una variable dependiente cualitativa con una o más variables independientes, por medio de la función de probabilidad generando el modelo de regresión logística siguiente ecuación 82:

$$y = p(x) + e \quad (82)$$

Donde la función de enlace  $p$  es:

$$p = \frac{e^{(b_0 + b_1 x_1 + \dots + b_n x_n)}}{1 + e^{(b_0 + b_1 x_1 + \dots + b_n x_n)}} \quad (83)$$

Teniendo que las variables  $x_1, \dots, x_n$  son el conjunto predictor, la variable  $y \in \{-1, +1\}$  es la salida, los  $b_0, b_1, b_2, \dots, b_n$  son los parámetros del modelo y  $e$  es un error aleatorio.

La probabilidad de que el conjunto pertenezca a una variable será la combinación lineal como muestra la función en la ecuación 84.

$$\log\left(\frac{p}{1-p}\right) = b_0 + b_1x_1 + \dots + b_nx_n \quad (84)$$

Se define  $z$  con el fin de simplificar la notación como observa en la ecuación 85.

$$z = b_0 + b_1x_1 + \dots + b_nx_n \quad (85)$$

Por tanto, podemos reescribir el modelo como puede ver en la ecuación 86.

$$p_i = \frac{1}{1 + e^{-z}} \quad (86)$$

Se emplean varias técnicas como la de gradiente descendiente, ecuación normal, o algoritmo evolutivo, con el fin de minimizar la función de coste  $J(b)$ , y encontrar el mejor ajuste a los datos.

**Regularización:** En regresión logística, se debe añadir a su función de coste,  $J(b)$ , el término  $\lambda R(b)$  donde  $\lambda$  es conocido como parámetro de regularización (*L2\_RLR-L2-Regularized Logistic Regression*) [131]. El parámetro  $\lambda$  da lugar a distorsiones en la función de coste, las mismas que pueden ocasionar un mal ajuste con los datos manejados.

#### 4.2.5 Redes Neuronales Artificiales

Las Redes Neuronales Artificiales (ANN) son modelos de procesamiento de la información cuya estructura y funcionamiento están inspirados en Redes neuronales biológicas.

Existen varios tipos de aprendizaje ANN, son ampliamente utilizados para el procesamiento de señal ECG, la detección automática de episodios isquémicos [132], la clasificación de seis diferentes tipos de ritmo ECG [133], etc.

Para que una ANN resuelva un problema dado, debe asociar un conjunto de patrones de entrada con un patrón deseado correspondiente de manera que se puede evaluar si la salida es la

deseada. El conjunto de entradas  $x_i(t)$  de la ANN es un conjunto de patrones que codifican la información de un problema que quiere ser resuelto, las variables de entrada y las de salidas pueden ser binarias (digitales) o continuas (analógica).

En este trabajo se utiliza ANN para resolver un problema de clasificación [134],[135] por lo que se denomina como ANNC.

Los datos de entrada  $x_i$ ;  $i = 1, 2, \dots, K$ , se clasificarán en una de las  $J$  clases y  $\theta = \{\theta_1, \dots, \theta_J\}$  es el conjunto de coeficientes asociados con la ANNC,  $\theta_j = \{\beta^j, w\}$  es el conjunto de los parámetros asociados al nodo de salida  $j$ .

El modelo es como se muestra en la ecuación 87.

$$f_j(x, \theta_j) = \beta_0^j + \sum_{i=1}^M \beta_i^j B_i(x, w_i), 1 \leq j \leq J - 1 \quad (87)$$

Donde  $\beta^j = \beta_0^j, \beta_1^j, \dots, \beta_m^j$  corresponden a los valores de las conexiones entre la capa oculta y el nodo  $j$  de la capa de salida,  $w = w_1, w_2, \dots, w_m$  son el conjunto de coeficientes asociados a los nodos de la capa oculta,  $w_j = w_{j0}, w_{j1}, \dots, w_{mjk}$  son los valores de las conexiones desde el nodo  $j$  de la capa oculta a la entrada, y  $B_i(x, w_i)$  la función de activación de nodo  $j$  de la capa oculta.

La unidad sigmoïdal es de la forma:

$$B_i(x, w_i) = \frac{1}{1 + \exp(w_{j0} - \sum_{i=1}^k w_{ij}x_i)} \quad (88)$$

Donde  $w_{j0}$  es el sesgo o bias.

La normalización de las salidas de la red puede interpretarse como la probabilidad de pertenecer a cada clase, tal como se da en la ecuación 89.

$$g_l(x, \theta_l) = \frac{\exp^{f_l(x, \theta_l)}}{\sum_1^J \exp^{f_l(x, \theta_l)}}, l = 1, 2, \dots, J - 1 \quad (89)$$

La transformación softmax, pueden interpretarse como probabilidades condicionales de pertenecer a una clase como se presenta en la ecuación 90.

$$P(y_l = 1 | x, \theta_j) = g_l(x, \theta_l), l = 1, 2, \dots, J - 1 \quad (90)$$

### 4.3 Entrenamiento

Cada conjunto de los vectores de características obtenidos mediante las técnicas usadas en esta tesis fueron separados en dos subconjuntos: subconjunto de entrenamiento y subconjunto de prueba.

Inicialmente, el subconjunto de aprendizaje se utiliza para que el algoritmo de clasificadores aprenda a discriminar entre los cuatro tipos de clases de patología. Los resultados obtenidos se optimizan hasta que los resultados del clasificador concuerdan con los parámetros adecuados. En cuanto el clasificador concluye el entrenamiento, genera una función de predicción que posteriormente es utilizada para evaluar nuevos datos introducidos al clasificador.

### 4.4 Arquitectura del procedimiento de clasificación

Con el fin de demostrar la independencia del método propuesto del algoritmo de clasificación, algunos algoritmos admiten sólo dos clases en el entrenamiento, mientras que en este caso son cuatro clases 'FV', 'TV', 'Otros' y 'Normal'. Por este motivo, se ha desarrollado un procedimiento donde todos los algoritmos de prueba están utilizando las cuatro clases, y proporcionan el mismo resultado de clasificación. El esquema de clasificación se muestra en la figura 38.

Inicialmente se generan tres pares {'FVTV', 'NormalOtros'}, {'FV', 'TV'} y {'Otros', 'Normal'}. A partir de los datos MD alcanzados anteriormente (en el capítulo 3), se generan tres subconjuntos de datos  $MD_i$  con  $i = \{1, 2, 3\}$ , donde cada uno de ellos corresponde a cada par arriba descrito.

**Fase de entrenamiento:** utilizando un sólo algoritmo de clasificación, para entrenar cada par y así crear una función de predicción  $Fp_i$  que corresponde a cada uno, para posteriormente ser utilizados en la prueba de nuevos datos introducidos al clasificador.

**Fase de prueba:** el tercio restante los datos MD se usan como prueba, empleando las tres funciones de predicción  $Fp_i$  obtenidas en la etapa de entrenamiento.

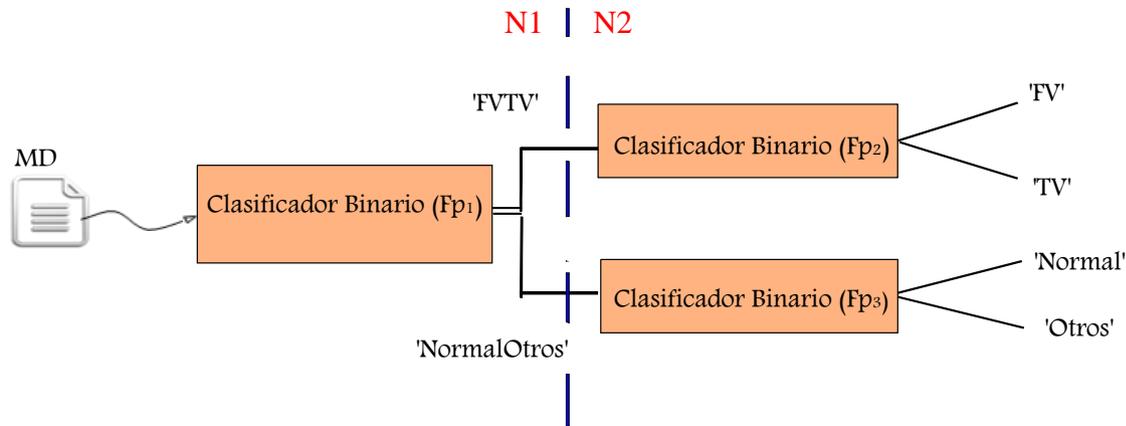


FIGURA 38. PROCEDIMIENTOS DE CLASIFICACIÓN (ETAPA DE LA PRUEBA).

En la fase de prueba los datos de la entrada se clasificaron con el esquema de dos niveles: El Nivel1 (N1), la muestra se clasificó en una de las dos clases: 'FVTV' y 'NormalOtros'. En el nivel2 (N2) tenemos que, si la muestra se estableció en el N1 como 'FVTV', entonces la salida del clasificador se marca de manera binaria como 'FV' o 'TV'. En el mismo N2, si la muestra se estableció en N1 como 'NormalOtros', entonces la salida del clasificador binario se marca como 'Normal' u 'Otros'.

En los resultados obtenidos en este capítulo, el mismo tipo de clasificador binario se usa en el primer y el segundo nivel de clasificación.

#### 4.4.1 Parámetros de los clasificadores

Cada uno de estos clasificadores tienen parámetros que deben ser optimizados con el objetivo de obtener el rendimiento máximo. La optimización de los parámetros de los clasificadores se evalúa a base del rendimiento final de clasificación, por lo tanto, se elige el valor del parámetro para el cual se obtenga el rendimiento máximo.

Para determinar el rendimiento de los parámetros durante el proceso de clasificación la medida empleada en esta investigación, es la tasa de error =  $\frac{\text{casos falsos}}{\text{casos falsos} + \text{casos verdaderos}}$  que se evalúa el número de casos mal clasificados (*casos falsos*), respecto a los casos totales evaluado (*casos falsos + casos verdaderos*).

Los parámetros de los clasificadores usados son:

- KNN: se utiliza la distancia euclídea,  $K=1$ .

- ANNC: Dos capas ocultas, 20 neuronas en cada capa oculta.
- SSVM: *Kernel* gaussiano ( $\gamma = 0.01$ ),  $Kernel(x_i; x) = exp^{-\gamma \|x_i - x\|}$ .
- BAGG: Se utilizan 600 árboles de decisión
- L2\_RLR: El parámetro de regularización ( $\lambda = 10^{-9}$ ) y  $R = \|b\|_2$ .

#### 4.4.2 Validación cruzada

Generalmente se eligen aleatoriamente dos tercios del total de los datos para ser usados en el entrenamiento, mientras que el tercio restante se usa para la prueba. Este enfoque se repite N veces. Seguidamente, el clasificador evalúa tomando en promedio el número de interacciones como se muestra en la figura 39

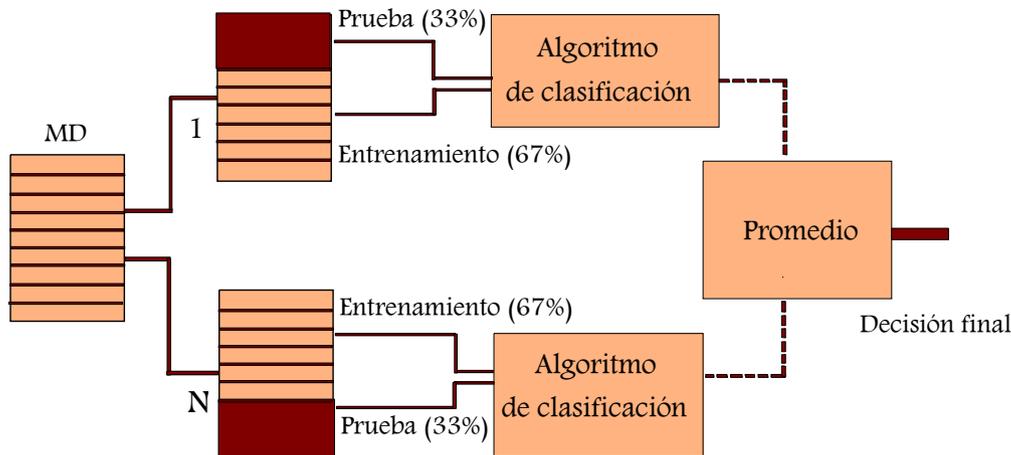


FIGURA 39. ALGORITMO DE VALIDACIÓN CRUZADA.

#### 4.5 Parámetros de evaluación

Un vez que se han explicado los métodos de clasificación y la arquitectura del procedimiento de clasificación utilizadas, es importante conocer la metodología empleada para validar los resultados que obtiene cada uno de los clasificadores.

Como parámetros de evaluación del rendimiento de la clasificación se utilizan los siguientes índices estadísticos estándar:

$$\text{Sensibilidad}(\%) = \frac{VP}{VP + FN} \times 100 \quad (91)$$

$$\text{Especificidad}(\%) = \frac{VN}{VN + FN} \times 100 \quad (92)$$

$$\text{Exactitud}(\%) = \frac{VP + VN}{VP + FN + VN + FP} \times 100 \quad (93)$$

Donde VP son los verdaderos positivos, FN los falsos negativos, VN los verdaderos negativos, y FP los falsos positivos [136].

El cálculo del valor de la especificidad global y de la exactitud global de una de las clases ('FV', 'TV', 'Otros', 'Normal') es la especificidad y exactitud de dicha clase de patología ante la suma de los tipos de patología restantes.

El tiempo de ejecución de cada una de las pruebas realizadas se midió empleando un PC de tipo Intel(R) Core(TM) i7-3612QM CPU @ 2.10 GHz con Memoria RAM de 8GB, sistema operativo de 64 bits y el programa Matlab(R).

## 4.6 Etapas de pruebas

De acuerdo a la metodología descrita en este y anterior capítulo, se organizó un esquema experimental para el análisis las cuatro clases de patologías. Este esquema incluye todos los procesos y pruebas mediante los clasificadores individuales, dicho esquema se detalla en la figura 40.

La metodología está planteada en cinco etapas:

**Primera Etapa:** consiste en implementar un algoritmo de filtro IIR, con el fin de reducir la línea base. Una vez filtrado, se proponen dos procesos diferentes para generar las ventanas  $V_t$ . En el primer proceso, que denominaremos Análisis Continuo (AC) dividiendo la señal ECG en ventanas  $V_t$  fijas de longitud de 1,2s.

En el segundo proceso, se desarrolla un algoritmo para obtener las Marcas MRV en la señal, donde cada MRV indica el comienzo de la  $V_t$  de longitud de 1,2s de la señal del ECG. En este caso se han tenido en cuenta los rangos normales de frecuencia cardiaca (ver el capítulo 3).

**Segunda Etapa:** donde, se usan las  $V_t$  obtenidas en la primera etapa para calcular la Transformada de Hilbert y después la RTF. Se han cancelado las contribuciones en frecuencia por encima de 45 Hz, con lo que se elimina tanto la interferencia de red (50Hz, 60Hz) como el

electromiograma EMG, obtenido una matriz de datos RTF de tamaño 45x150 que dará lugar a diferentes tipos de matrices MD' que servirán de entrada al clasificador.

Además, en esta segunda etapa se realizó la comprobación de seis filtros de la línea base y siete RTF empleando las  $V_t$  obtenidas mediante MRV.

**Tercera Etapa:** la RTF obtenida en la segunda etapa se las convirtió en IRTF de tamaño 45x150, las cuales fueron cada una almacenadas en una matriz MD'' (no reducida).

**Cuarta Etapa:** como he mencionado anteriormente (ver capítulo3) se realizó la disminución de dimensionalidad de los datos obtenidos en la tercera etapa en dos formas: reducción del tamaño de IRTF y SC.

La reducción del tamaño IRTF empleó cuatro técnicas (la media de la intensidad de los píxeles, KNN, la técnica Bilineal y la técnica Bicúbica), y luego, cada imagen reducida quedó almacenadas en una matriz MD''' de tamaño 3x5.

En la SC de las MD'' obtenidos mediante IRTF no reducida, se obtuvieron un Número de Características (NC) que se seleccionaron y almacenaron en una nueva MD de tamaño reducido ( $V_{sc}$ ). Como resultado de esta selección, se tomaron en cuenta aquellas que poseen características de información más importante, eliminando así las características de información que no contribuyen de manera significativa al proceso.

**Quinta Etapa:** se usan todas las MD obtenidas anteriormente mediante cada técnica como matriz de entrada para los algoritmos de clasificación tanto en el entrenamiento como en las pruebas del algoritmo de clasificación individual usando la estrategia comentada en la sección 4.2.

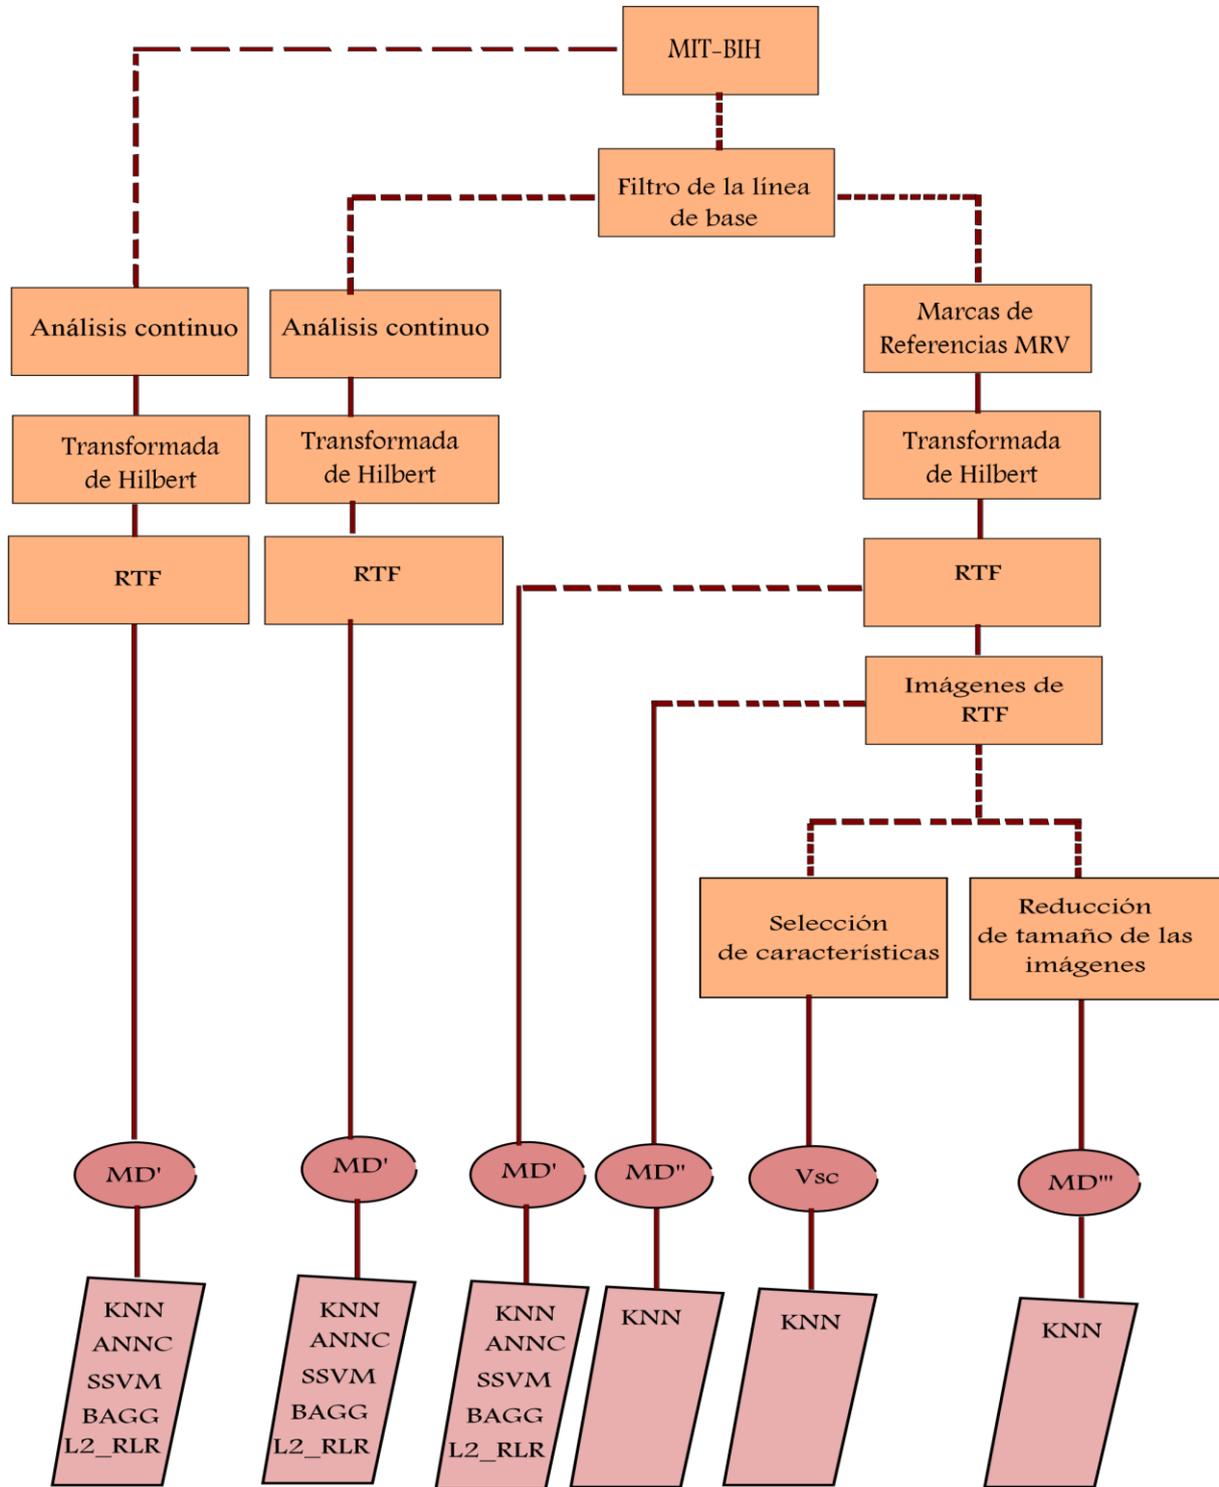


FIGURA 40. ESQUEMA GENERAL DE LOS PROCESOS SEGUIDO APLICANDO LOS CLASIFICADORES INDIVIDUALES.

En todas las pruebas de esta investigación, el desempeño de clasificación se basa en entrenar un 67 % de las observaciones y el restante un 33% queda para validación. Estas se eligieron aleatoriamente para cada una mediante validación cruzada.

Este enfoque se repitió al azar por cinco veces  $N=5$  (ver la figura 39) y el rendimiento global de los clasificadores se evaluó tomando el promedio de estas cinco interacciones.

## 4.7 Clasificación mediante análisis de RTF

Como fue explicado anteriormente, en esta parte vamos a hablar sobre los resultados de los datos MD' obtenidos de la RTF de tipo PWV.

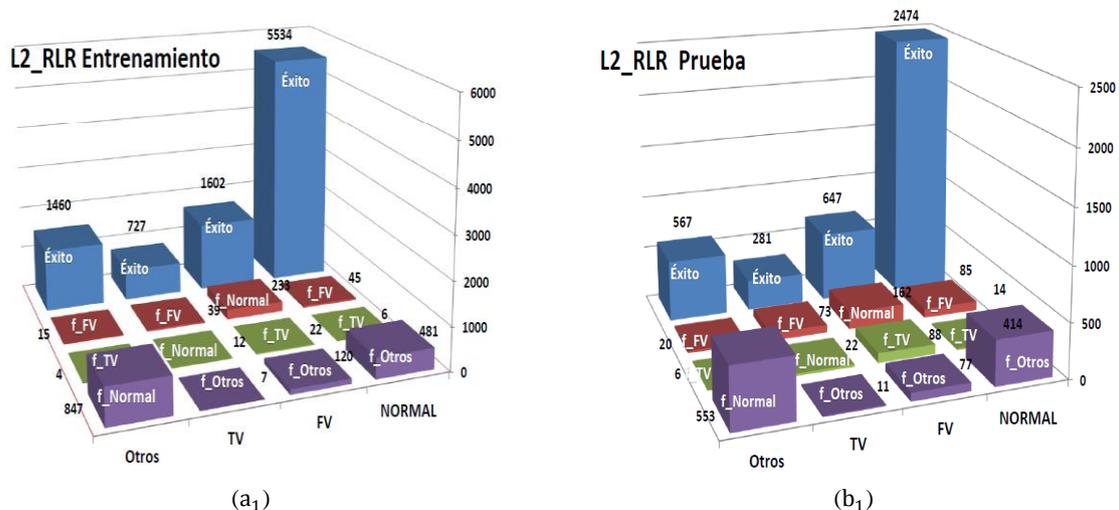
### 4.7.1 Análisis continuo

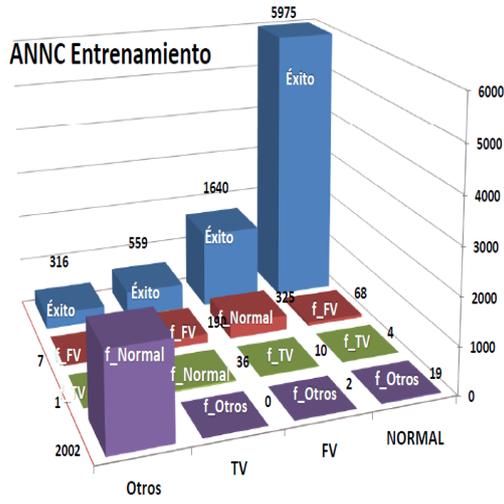
Esta prueba se basa en dividir la señal ECG en ventanas de longitud fija 1,2s. Se evaluaron los modos sin filtro y con filtro para la comparación del desempeño de los algoritmos de clasificación ANNC, SSVM, BAGG, L2\_RLR y KNN.

#### Sin usar el filtro de la línea base

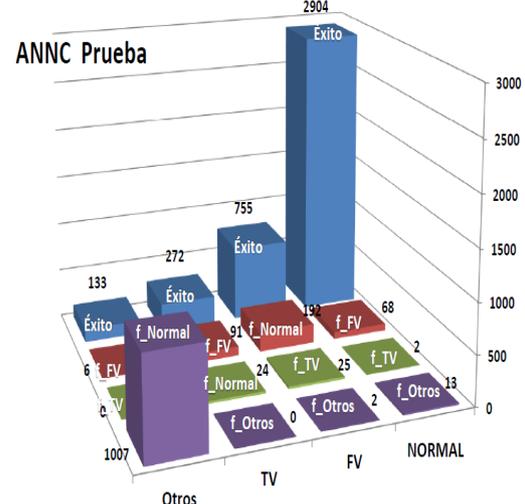
Se realiza una evaluación del resultado de los clasificadores para la señal de ECG ruidosa sin emplear filtro de la línea base.

La figura 41 muestra los resultados obtenidos para los cinco algoritmos de clasificación ANNC, SSVM, BAGG, L2\_RLR y KNN para una sola iteración del entrenamiento (train) y prueba (test) de un conjunto de datos asignados aleatoriamente. Además, indican el número de casos clasificados como éxito y error para cada una de las clases.

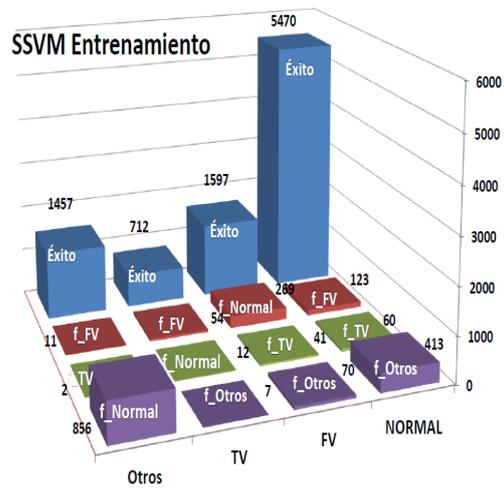




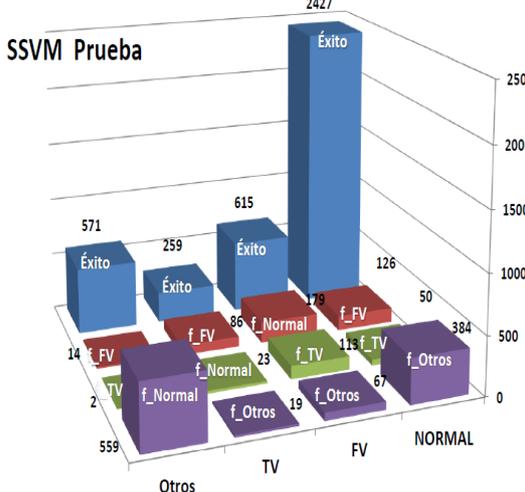
(a<sub>2</sub>)



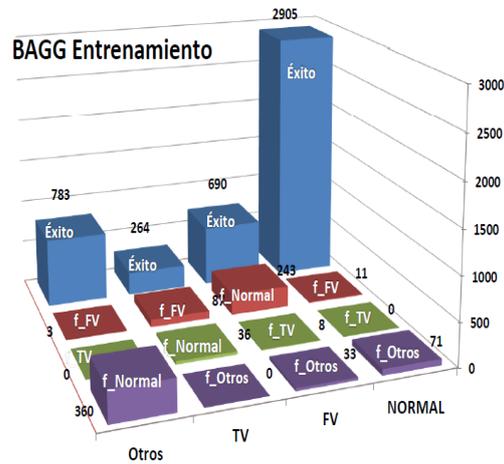
(b<sub>2</sub>)



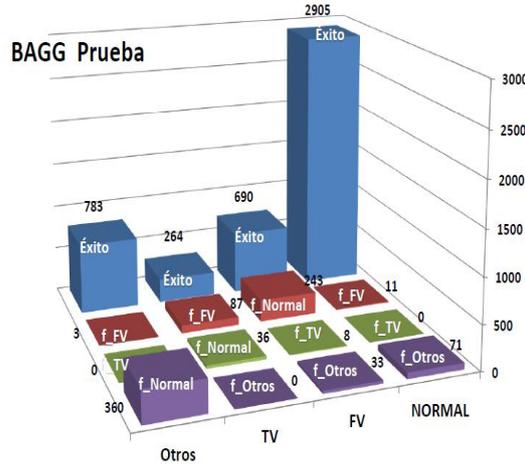
(a<sub>3</sub>)



(b<sub>3</sub>)



(a<sub>4</sub>)



(b<sub>4</sub>)

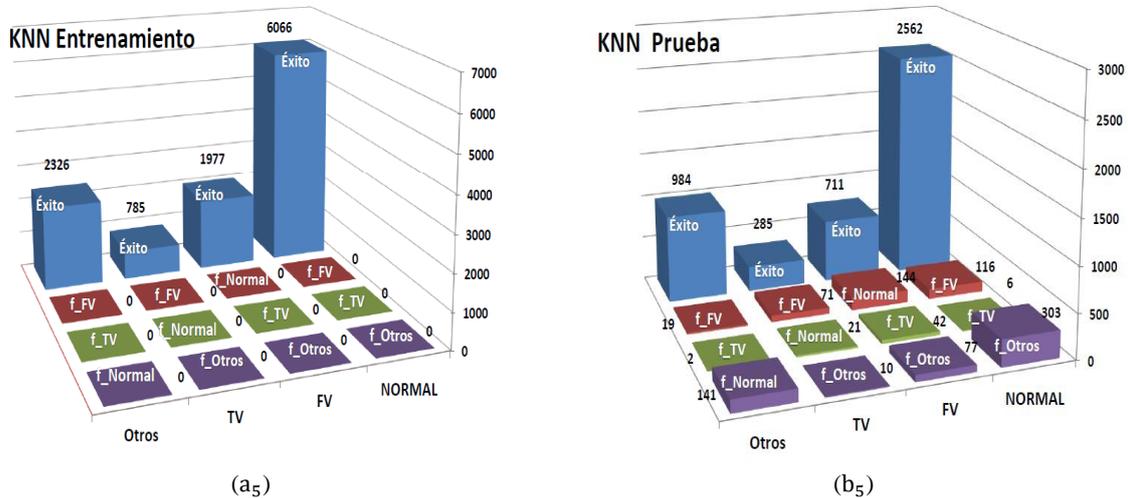


FIGURA 41. RESULTADOS PARA UNA ITERACIÓN DEL ENTRENAMIENTO Y LA PRUEBA DE UN CONJUNTO DE DATOS ASIGNADOS ALEATORIAMENTE MEDIANTE CINCO CLASIFICADORES, USANDO LA TÉCNICA DE ANÁLISIS CONTINUO AC.

Como se aprecia en la figura 41b, los resultados obtenidos de los cinco clasificadores muestran que la mayoría de las clases ‘FV’ y ‘TV’ no fueron clasificadas como clases ‘FV’ y ‘TV’ esperadas, respectivamente.

Por ejemplo, KNN en la detección de clases ‘FV’ fue de 711 ventanas como clase ‘FV’, y una suma de 263 ventanas como otras clases ‘TV’, ‘Otros’ y ‘Normal’. Así mismo, en el caso de ‘TV’, 285 ventanas fueron detectadas como clase ‘TV’, y una suma de 102 ventanas como clases ‘FV’, ‘Otros’ y ‘Normal’.

Los resultados de Sensibilidad (Sens), Especificidad (Esp) y Exactitud (Exa) de las cuatro clases se muestran en las tablas 2 y 3, para cada clasificador.

Analizando los resultados ofrecidos por los diferentes algoritmos propuestos en las tablas 2 y 3, se observa que los algoritmos presentan porcentajes bajo de clasificación. Además, se visualiza cierta variabilidad en cuanto a estos porcentajes para diferentes valores de la sensibilidad de ‘FV’ y ‘TV’, con valores que van del 59% al 76%. También se aprecia que la diferenciación entre ‘Otros’ y ‘Normal’ es muy baja, excepto en el caso en que se utilizan los algoritmos KNN.

TABLA 2. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD DE LA DETECCIÓN DE LAS PATOLOGÍAS ('FV', 'TV') OBTENIDOS POR CINCO ALGORITMOS DE CLASIFICACIÓN, USANDO AC.

Clases	FV						TV					
	Índices Estadísticos	Sens%	Esp%				Exa%	Sens%	Esp%			
Algoritmos	FV	Global	TV	Otros	Normal	Global	TV	Global	FV	Otros	Normal	Global
<b>L2_RLR</b>												
<b>Sin Filtro</b>	66,73	95,20	76,14	96,61	97,44	89,00	67,63	97,08	88,04	99,18	99,26	94,38
<b>Con Filtro</b>	82,64	96,15	76,43	97,81	98,30	93,44	71,49	97,02	88,16	99,65	99,23	94,95
<b>ANNC</b>												
<b>Sin Filtro</b>	61,95	95,13	68,08	82,13	98,16	87,93	59,58	98,37	90,79	95,95	99,72	94,76
<b>Con Filtro</b>	85,72	95,58	72,54	92,83	97,93	93,63	68,93	98,64	94,05	99,27	99,82	96,23
<b>SSVM</b>												
<b>Sin Filtro</b>	63,14	93,51	75,07	97,61	95,06	86,87	66,93	95,63	84,48	99,65	97,98	92,97
<b>Con Filtro</b>	75,87	94,17	73,16	96,82	96,11	90,48	66,93	96,60	87,66	99,30	98,63	94,12
<b>BAGG</b>												
<b>Sin Filtro</b>	72,77	97,16	71,86	99,26	99,61	92,43	64,44	99,84	99,13	99,92	100	96,98
<b>Con Filtro</b>	89,81	97,09	72,60	99,79	99,25	95,74	68,83	99,90	99,54	100	100	97,58
<b>KNN</b>												
<b>Sin Filtro</b>	74,40	94,84	77,54	97,66	96,08	90,89	70,92	98	94,70	99,84	99,85	96,64
<b>Con Filtro</b>	88,26	97,44	80,85	99,32	98,86	95,73	75,71	99,10	95,51	100	99,91	97,35

Se puede concluir que la discriminación entre 'TV' y 'FV' no es efectiva, lo que muestra una inestabilidad en el método de clasificación debido a la confusión entre estas clases, que se debe principalmente a las similitudes morfológicas entre clase 'TV' y la clase del 'FV'.

### Con filtro de la línea base

En este punto se realizaron los mismos pasos anteriores, pero esta vez se aplicó RTF luego de utilizar el filtro de la línea base descrito en el capítulo 3.

Se realizaron comparaciones entre los valores de la sensibilidad, la especificidad y exactitud de los resultados alcanzados en las respectivas clases, análogamente a los mostrados en las tablas 2 y 3.

El clasificador KNN, fue el mejor, donde los porcentajes de sensibilidad de 'FV' y 'TV' son superiores al 75%. Usando dicho clasificador se obtiene una sensibilidad de 88,26%, una especificidad global 97,44% y exactitud global 95,73% para 'FV', mientras que para 'TV' se observó una sensibilidad del 75,71%, una especificidad global 99,10% y exactitud global 97,35%.

TABLA 3. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD DE LA DETECCIÓN DE LAS PATOLOGÍAS ('NORMAL', 'OTROS') OBTENIDOS POR CINCO ALGORITMOS DE CLASIFICACIÓN, USANDO AC.

Clases	Otros						Normal					
	Índices Estadísticos	Sens%	Esp%				Exa%	Sens%	Esp%			
Algoritmos	Otros	Global	TV	Normal	FV	Global	Normal	Global	FV	TV	Otros	Global
<b>L2_RLR</b>												
Sin Filtro	49,82	87,29	94,36	85,96	89,96	78,79	83,54	66,67	79,9	90,4	50,92	76,34
Con Filtro	75,51	91,09	97,19	88,70	97,45	87,64	86,77	86,06	95,30	94,20	77,01	86,46
<b>ANNC</b>												
Sin Filtro	32,68	94,71	97,00	95,10	91,79	80,24	93,21	53,30	69,20	84,80	33,13	75,94
Con Filtro	55,41	97,25	99,70	96,74	98,21	88,03	94,63	74,75	92,00	93,4	56,04	85,91
<b>SSVM</b>												
Sin Filtro	49,83	87,54	93,17	86,34	90,18	78,75	81,25	65,50	77,46	91,84	50,53	74,56
Con Filtro	74,35	90,61	97,74	88,53	95,85	86,90	84,47	82,74	88,19	90,56	76,62	83,73
<b>BAGG</b>												
Sin Filtro	67,87	97,54	99,83	97,71	96,06	90,88	97,34	73,32	75,50	86,30	68,25	86,72
Con Filtro	84,95	99,05	100	98,79	99,66	95,98	98,05	88,23	90,50	93,00	85,10	93,68
<b>KNN</b>												
Sin Filtro	84,85	90,62	96,82	89,90	90,99	89,32	86,61	86,44	85,90	90,2	86,73	86,54
Con Filtro	89,79	96,65	99,77	95,36	97,95	95,16	94,83	91,99	93,90	92,40	90,34	93,57

Cuando se utilizó el algoritmo de BAGG se obtuvieron valores con una sensibilidad del 89,81%, una especificidad global 97,09% y exactitud global del 95,74% para 'FV' y con una sensibilidad del 68,83%, una especificidad global del 99,90% y exactitud global del 97,58% para 'TV'.

Los resultados obtenidos mediante el algoritmo de clasificación L2\_RLR para la detección de 'FV', mostraron un sensibilidad del 82,64%, una especificidad global del 96,15% y Exactitud global del 93,44%, mientras que para 'TV' se obtuvo una sensibilidad del 71,49%, una especificidad global del 97,02% y exactitud global del 94,95%. Al usar el algoritmo de clasificación SSVM para la detección de 'FV' se obtuvo un sensibilidad del 75.87%, una especificidad global del 94.17% y exactitud global del 90,48%, mientras que para 'TV' se obtuvo una sensibilidad del 66.93 %, una especificidad global del 96.60% y exactitud global del 94.12%.

Cuando se utilizó el algoritmo de ANNC, la sensibilidad fue 85,72% con una especificidad global del 95,58% y exactitud global del 93,63% para 'FV', mientras que para 'TV' se observó una sensibilidad del 68,93%, una especificidad global del 98,64% y exactitud global del

96,23%. Se puede decir que utilizando este algoritmo no se logra alcanzar el rendimiento obtenido con el algoritmo de KNN.

En el análisis para la detección de 'FV' y 'TV' mediante ésta prueba con los cinco algoritmos, se observa que tanto la sensibilidad como la especificidad global se encuentran entre el 68,83 % y el 89, 81 %, por consiguiente, superiores a los obtenidos de la clasificación anterior (caso de sin usar el filtro de la línea base).

Se puede concluir que, debido principalmente a la gran similitud entre las señales 'TV' y 'FV', es muy complicado conseguir elevados resultados de clasificación utilizando la estrategia de análisis continuo. Esto obliga a buscar otro procedimiento para abordar el problema de discriminación de las clases, para lo cual se va a emplear la metodología de obtención de marcas MRV combinado con RTF.

#### **4.7.2 Marcas de Referencias de las Ventanas**

Esta parte de la investigación plantea una nueva estrategia, la que se desarrolló empleando las MRV con el objetivo generar las ventanas  $V_t$ , como fue señalado anteriormente en el capítulo 3.

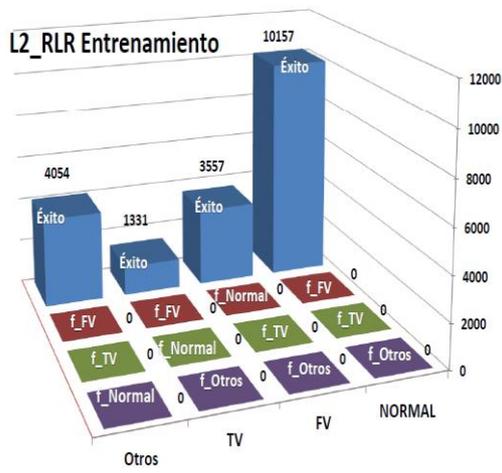
En total, se generaron 28507 ventanas para todas las MD' registradas; 5309 correspondieron a la clase 'FV', 1987 a 'TV', 6051 a 'Otros' y 15160 a 'Normal', en los cuales se emplean como entrada del clasificador y los resultados logrados se definieron de acuerdo a las tres pruebas que se llevaron a cabo.

La primera prueba está basada en diferentes tipos de algoritmos de clasificación usando PWV con filtro de tipo IIR, la segunda es empleando varios RTF combinadas con el filtro IIR y por último, se utilizan los filtros FIR, IIR, media móvil, smooth, wavelet y mediana, los mismos que se combinaron con PWV. En la segunda y tercera prueba se usa KNN.

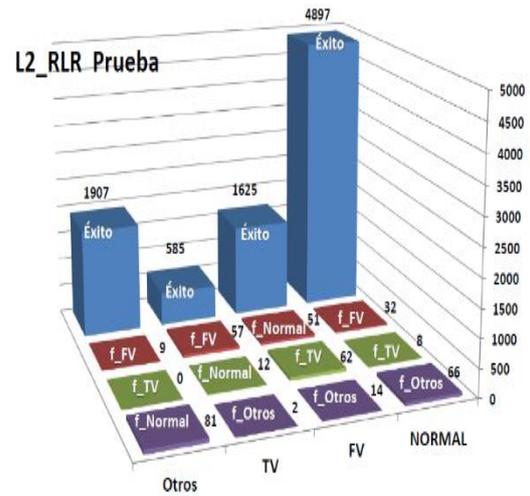
##### **4.7.2.1 Análisis basado en diferentes tipos de algoritmos de clasificación**

En esta primera prueba, los resultados se obtienen mediante diferentes tipos de algoritmos de clasificación ANNC, SSVM, BAGG, L2\_RLR y KNN, usando PWV combinada con el filtro de tipo IIR.

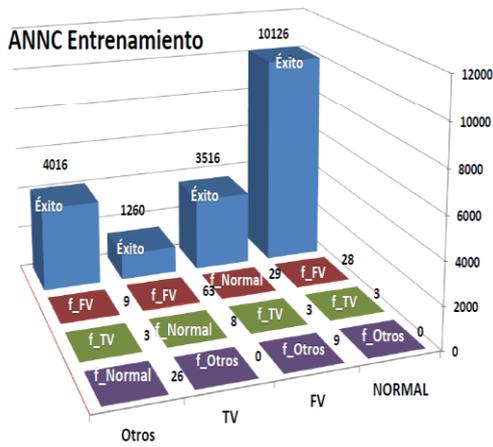
La figura 42 representa los resultados para una sola iteración del número de casos de éxito y error para las diferentes clases de patologías tanto en el entrenamiento como la prueba de los clasificadores.



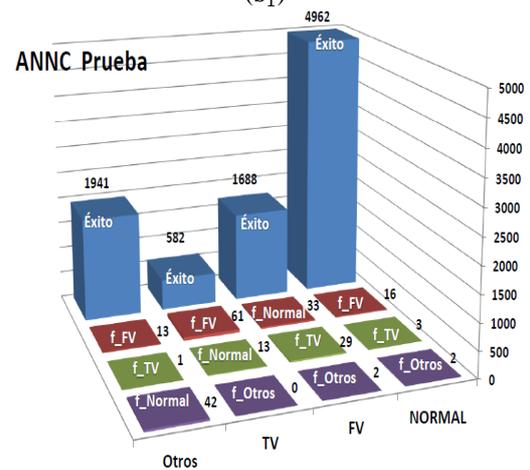
(a<sub>1</sub>)



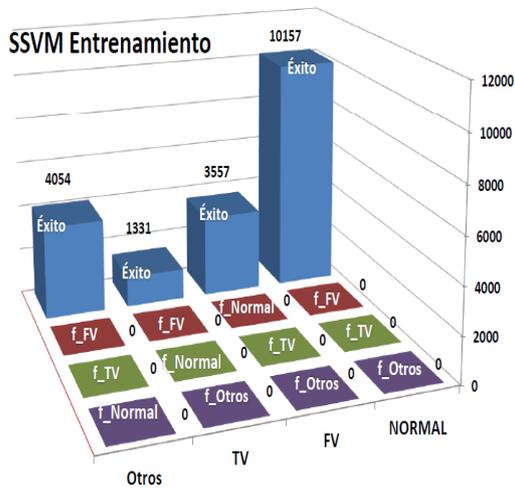
(b<sub>1</sub>)



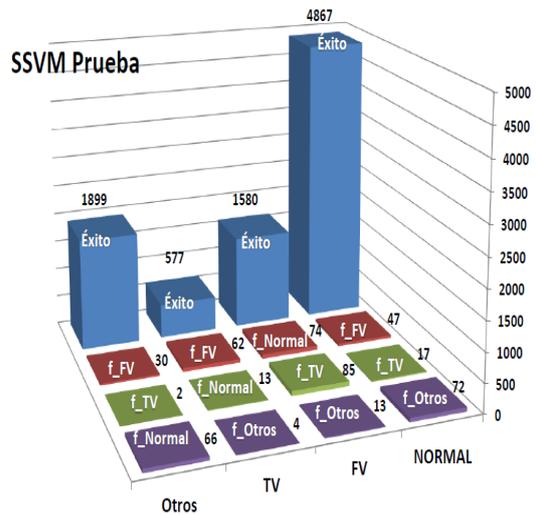
(a<sub>2</sub>)



(b<sub>2</sub>)



(a<sub>3</sub>)



(b<sub>3</sub>)

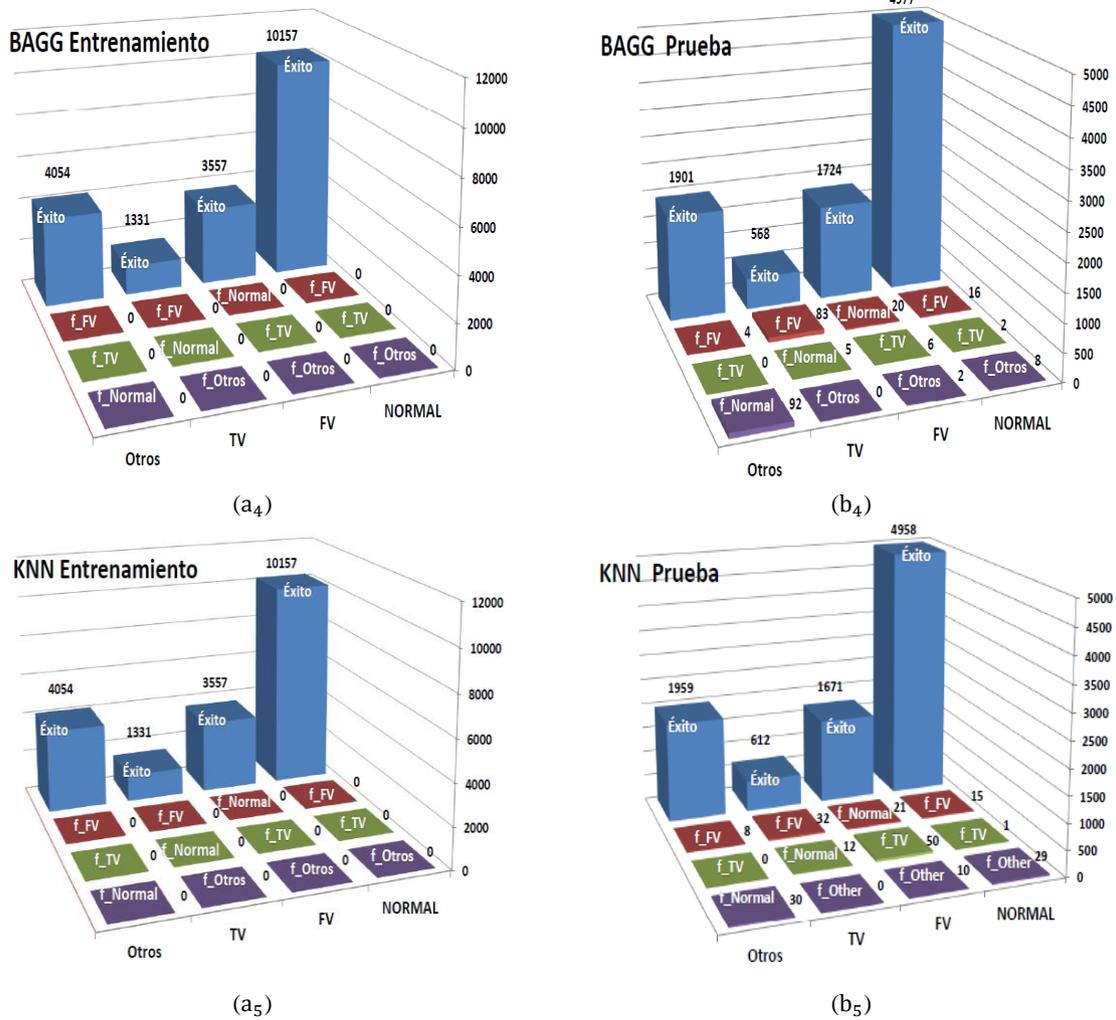


FIGURA 42. RESULTADOS PARA UNA ITERACIÓN DEL ENTRENAMIENTO Y LA PRUEBA DE UN CONJUNTO DE DATOS ASIGNADOS ALEATORIAMENTE MEDIANTE CINCO CLASIFICADORES, USANDO LA TÉCNICA DE MRV.

En el caso de los clasificadores L2RLR, KNN, BAGG y SSVM, los resultados son mejores que los obtenidos utilizando ANNC, mostrando una mejor capacidad de aprendizaje del conjunto de datos de entrenamiento (ver la figura 42a) mientras que en el caso de la prueba aparecen fallos en los resultados (ver la figura 42b).

Las tablas 4 y 5 resumen los resultados alcanzados al realizar comparaciones entre los valores de sensibilidad, especificidad y exactitud logrados en las respectivas cuatro clases.

TABLA 4. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD DE LA DETECCIÓN DE LAS PATOLOGÍAS ('FV', 'TV') OBTENIDOS POR CINCO ALGORITMOS DE CLASIFICACIÓN, USANDO LA TÉCNICA DE MRV.

Clases	FV						TV						
	Índices Estadísticos	Sens%	Esp%				Exa%	Sens%	Esp%				Exa%
			Global	TV	Otros	Normal			Global	TV	Global	FV	
Algoritmos	FV	Global	TV	Otros	Normal	Global	TV	Global	FV	Otros	Normal	Global	
<b>L2_RLR</b>													
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100	
<b>Test</b>	91,54	98,45	89,75	99,31	99,21	97,15	88,15	98,81	94,85	99,84	99,75	98,07	
<b>ANNC</b>													
<b>Train</b>	99,01	99,56	97,25	99,70	99,79	99,46	96,08	99,95	99,82	100	99,98	99,69	
<b>Test</b>	95,56	98,80	90,12	99,74	99,51	98,19	88,80	99,52	97,64	100	99,98	98,87	
<b>SSVM</b>													
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100	
<b>Test</b>	90,00	98,13	89,02	98,99	98,92	96,60	86,85	98,63	94,77	99,47	99,60	97,82	
<b>BAGG</b>													
<b>Train</b>	100	99,99	99,92	100	100	99,99	99,92	100	100	100	100	99,99	
<b>Test</b>	98,46	98,43	84,99	99,79	99,59	98,44	84,8	99,86	99,52	99,95	99,94	98,82	
<b>KNN</b>													
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100	
<b>Test</b>	94,97	99,27	95,21	99,63	99,66	98,47	93,47	99,39	96,98	99,99	99,98	98,97	

Al analizar los valores presentes en las tablas 4, 5. Una parte al emplear el clasificador KNN, para 'FV' se obtuvo una sensibilidad del 94,97%, una especificidad global del 99,27% y exactitud global del 98,47%. Para 'TV' una sensibilidad del 93,47%, especificidad global del 99,39% y exactitud global del 98,97%.

Por otra parte, se puede ver que los clasificadores BAGG y L2\_RLR se comportan de manera similar para las clases 'Normal' y 'Otros'. Para la clase 'Normal' presentó una sensibilidad del 99,39%; 97,63%, una especificidad global del 97,61%; 96,61% y exactitud global del 98,57%, 97,17%. Para la clase 'Otros' mostró una sensibilidad del 95,66%; 94,807%, una especificidad global del 99,87%; 98,79% y exactitud global del 98,95%; 97,91%. Sin embargo, el clasificador BAGG tiene mejor sensibilidad de 98,64% para 'FV' y menor sensibilidad de 84,58% para 'TV', en comparación con el clasificador L2\_RLR el cual presenta una menor sensibilidad de 91,54% para 'FV' y mayor sensibilidad de 88,15% 'TV'.

Al emplear el clasificador ANNC se obtuvo una sensibilidad del 95,56%, una especificidad global del 98,80% y una exactitud global del 98,19% para 'FV', una sensibilidad del 88,80%, una especificidad global del 99,52% y exactitud global del 98,87% para 'TV'.

Comparando los resultados ofrecidos por los diferentes algoritmos, existe una importante variación en los resultados de sensibilidad ante 'FV' y sensibilidad ante 'TV' dependiendo del

algoritmo empleado, si el nivel de sensibilidad ‘FV’ es alto, entonces el de sensibilidad para ‘TV’ disminuye.

TABLA 5. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD DE LA DETECCIÓN DE LAS PATOLOGÍAS (‘NORMAL’, ‘OTROS’) OBTENIDOS POR CINCO ALGORITMOS DE CLASIFICACIÓN, USANDO LA TÉCNICA DE MRV.

Clases	Otros					Normal						
	Sens%	Esp%				Sens%	Esp%					
Algoritmos	Otros	Global	TV	Normal	FV	Global	Normal	Global	FV	TV	Otros	Global
<b>L2_RLR</b>												
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100
<b>Test</b>	94,80	98,79	100	96,4	98,85	97,91	97,63	96,61	97,42	98,01	95,57	97,17
<b>ANNC</b>												
<b>Train</b>	98,04	99,92	99,83	99,94	99,91	99,51	99,71	98,79	99,27	98,93	98,33	99,2
<b>Test</b>	96,87	99,55	100	99,49	99,57	98,96	98,98	97,72	98,24	98,38	97,11	98,40
<b>SSVM</b>												
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100
<b>Test</b>	94,29	98,90	99,63	98,92	98,57	97,87	97,49	96,08	96,03	97,63	95,69	96,85
<b>BAGG</b>												
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100
<b>Test</b>	95,66	99,87	100	99,86	99,88	98,95	99,39	97,61	99,05	99,43	95,90	98,57
<b>KNN</b>												
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100
<b>Test</b>	97,69	99,40	99,87	99,42	99,28	99,03	99,07	98,29	98,70	98,11	98,03	98,71

Otra vez se puede ver que el clasificador KNN alcanza el mejor rendimiento para la metodología propuesta, debido a la capacidad de detección y discriminación adecuada de la ‘FV’ frente al resto de patologías, por lo que se considera bastante aceptable y por consiguiente se eligió para la realización de las posteriores pruebas.

#### 4.7.2.2 Análisis basado en varios tipos de RTF usando el algoritmo KNN

En esta segunda prueba, para evaluar el desempeño de diferentes RTF en la detección de FV, se empleó el filtro de la línea base IIR.

Se obtuvieron las RTF de BJD, Wavelet, STFT, SPWV, CDW, DBessel y PWV (ver el capítulo 3). Se realizaron comparaciones entre los valores de la sensibilidad, especificidad y exactitud de los resultados en las respectivas clases, los cuales se muestran en las tablas 6 y 7.

Al analizar los resultados alcanzados que se muestran en las tablas 6 y 7, se puede ver que la mayoría de los valores de sensibilidad de las cuatro clases obtenidos en el clasificador KNN usando diferentes RTF, están por encima del 93%. Además, sus valores de especificidad global son superiores al 94%.

TABLA 6. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD DE LA DETECCIÓN DE LAS PATOLOGÍAS ('FV', 'TV') OBTENIDOS POR EL ALGORITMO KNN, USANDO VARIOS TIPOS DE RTF.

Clases	FV						TV					
	Índices Estadísticos	Sens%	Esp%				Exa%	Sens%	Esp%			
RTF	FV	Global	TV	Otros	Normal	Global	TV	Global	FV	Otros	Normal	Global
<b>BJD Train Test</b>	100 94,74	100 99,24	100 94,67	100 99,60	100 99,70	100 98,40	100 93,17	100 99,34	100 96,70	100 99,99	100 100	100 98,90
<b>WAVELET Train Test</b>	100 93,91	100 99,02	100 95,60	100 99,15	100 99,43	100 98,07	100 95,90	100 99,05	100 95,57	100 99,91	100 99,93	100 98,76
<b>STFT Train Test</b>	100 95,36	100 99,41	100 95,04	100 99,84	100 99,81	100 98,65	100 94,72	100 99	100 96,51	100 99,98	100 99,95	100 96,95
<b>SPWV Train Test</b>	100 94,40	100 99,27	100 94,73	100 99,63	100 99,72	100 99,36	100 93,81	100 99,29	100 96,47	100 99,99	100 99,98	100 98,90
<b>CDW Train Test</b>	100 94,53	100 99,28	100 94,68	100 99,67	100 99,73	100 98,39	100 93,47	100 99,32	100 96,62	100 99,99	100 99,99	100 98,91
<b>DBessel Train Test</b>	100 95,05	100 99,29	100 95,84	100 99,49	100 99,69	100 98,49	100 93,97	100 99,38	100 96,91	100 99,98	100 99,99	100 98,99
<b>PWV Train Test</b>	100 94,97	100 99,27	100 95,21	100 99,63	100 99,66	100 98,47	100 93,47	100 99,39	100 96,98	100 99,99	100 99,98	100 98,97

Al usar el método basado en PWV el cual ofrece buenos resultados, con una sensibilidad del 94,97%, una especificidad global del 99,27% y una exactitud global del 98,47% para 'FV'. En el caso de 'TV' una sensibilidad del 93,47%, una especificidad global del 99,39% y exactitud global del 98,79%. Para la señal de tipo 'Normal' se observa una sensibilidad del 99,07%, una especificidad global del 98,29% y exactitud global del 98,71%. También se muestra una sensibilidad del 97,69%, una especificidad global del 99,40% y exactitud global del 99,03%, para la clase 'Otros'.

Análogamente, para el resto de los métodos de RTF se consiguen resultados similares a los conseguidos para PWV, debido a que no existe gran diferencia entre la mayoría de los tipos de métodos RTF usados.

Se eligió la RTF de tipo PWV tomando en consideración trabajos previos, para la realización de las posteriores pruebas.

TABLA 7. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD DE LA DETECCIÓN DE LAS PATOLOGÍAS (‘NORMAL’, ‘OTROS’) OBTENIDOS POR EL ALGORITMO KNN, USANDO VARIOS TIPOS DE RTF.

Clases	Otros						Normal					
	Índices Estadísticos	Sens%	Esp%				Exa%	Sens%	Esp%			
RTF	Otros	Global	TV	Normal	FV	Global	Normal	Global	FV	TV	Otros	Global
<b>BJD Train Test</b>	100 97,54	100 99,45	100 99,93	100 99,46	100 99,24	100 99,03	100 99,22	100 98,27	100 78,9	100 98,40	100 97,93	100 98,75
<b>WAVELET Train Test</b>	100 97,30	100 99,57	100 99,96	100 99,59	100 99,35	100 99,07	100 98,95	100 98,59	100 98,8	100 99,30	100 98,19	100 98,78
<b>STFT Train Test</b>	100 98,62	100 99,75	100 100	100 99,79	100 99,56	100 99,50	100 99,56	100 99,07	100 99,20	100 99,60	100 98,80	100 99,33
<b>SPWV Train Test</b>	100 97,90	100 99,43	100 100	100 99,50	100 99,06	100 99,10	100 99,21	100 98,53	100 98,70	100 99,00	100 98,26	100 98,89
<b>CDW Train Test</b>	100 97,82	100 88,39	100 99,90	100 99,43	100 99,11	100 99,05	100 99,15	100 98,41	100 98,6	100 98,70	100 98,14	100 98,79
<b>DBessel Train Test</b>	100 97,61	100 99,45	100 100	100 99,44	100 99,32	100 99,05	100 99,1	100 98,31	100 98,7	100 98,00	100 98,11	100 98,73
<b>PWV Train Test</b>	100 97,69	100 99,40	100 99,87	100 99,42	100 99,28	100 99,03	100 99,07	100 98,29	100 98,70	100 98,11	100 98,03	100 98,71

#### 4.7.2.3 Análisis basados en varios filtros de la línea base usando el algoritmo KNN

Finalmente, igual que en la prueba anterior realizada para evaluar RTF, esta vez se prueban distintos filtros de la línea base (IIR, FIR, media móvil, smooth, Wavelet, mediana), para lo cual se empleó la RTF (PWV) usando el algoritmo KNN.

Los resultados obtenidos se muestran en las tablas 8 y 9.

Como se puede observar en las tablas anteriores, los filtros FIR, media, smooth e IIR tienen valores que rondan el 94% de sensibilidad para ‘FV’ y el 92% de sensibilidad para ‘TV’, sin embargo, los resultados obtenidos para el resto de filtros son menores como es el caso del Wavelet. Este logró una sensibilidad del 92, 63%, una especificidad Global del 99,10% y una exactitud global del 97,91% para la ‘FV’. Para este mismo filtro, se encontró una sensibilidad del 91,27%, una especificidad global del 99,08% y una exactitud global del 98, 51% para la ‘TV’.

TABLA 8. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD DE LA DETECCIÓN DE LAS PATOLOGÍAS ('FV', 'TV') OBTENIDOS POR EL ALGORITMO KNN, USANDO VARIAS TÉCNICAS DE FILTROS DE LA LÍNEA BASE Y RTF DE TIPO PWV.

Clases	FV						TV					
Índices Estadísticos	Sens%	Esp%				Exa%	Sens%	Esp%				Exa%
Filtros	FV	Global	TV	Otros	Normal	Global	TV	Global	FV	Otros	Normal	Global
<b>FIR Train Test</b>	100 93,64	100 99,10	100 93,18	100 99,53	100 99,68	100 98,09	100 91,33	100 99,18	100 95,90	100 99,98	100 99,98	100 98,63
<b>IIR Train Test</b>	100 94,97	100 99,27	100 95,21	100 99,63	100 99,66	100 98,47	100 93,47	100 99,39	100 96,98	100 99,99	100 99,98	100 98,97
<b>Media Móvil Train Test</b>	100 94,22	100 99,00	100 93,56	100 99,60	100 99,45	100 98,12	100 92,10	100 99,21	100 96,10	100 99,96	100 99,96	100 98,72
<b>Smooth Train Test</b>	100 94,29	100 99,13	100 93,72	100 99,58	100 99,63	100 98,24	100 92,10	100 99,24	100 96,19	100 99,97	100 99,98	100 98,75
<b>Wavelet Train Test</b>	100 92,63	100 99,10	100 94,16	100 99,60	100 99,56	100 97,91	100 91,27	100 99,08	100 95,45	100 99,96	100 99,96	100 98,51
<b>Mediana Train Test</b>	100 95,56	100 98,99	100 92,44	100 99,70	100 99,52	100 98,36	100 90,89	100 99,39	100 97,04	100 99,96	100 90,97	100 98,81

TABLA 9. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD DE LA DETECCIÓN DE LAS PATOLOGÍAS ('NORMAL', 'OTROS') OBTENIDOS POR EL ALGORITMO KNN, USANDO VARIAS TÉCNICAS DE FILTROS DE LA LÍNEA BASE Y RTF DE TIPO PWV.

Clases	Otros						Normal					
Índices Estadísticos	Sens%	Esp%				Exa%	Sens%	Esp%				Exa%
Filtros	Otros	Global	TV	Normal	FV	Global	Normal	Global	FV	TV	Otros	Global
<b>FIR Train Test</b>	100 97,33	100 99,29	100 90,73	100 99,30	100 99,10	100 98,89	100 99,00	100 98,08	100 98,50	100 98,06	100 97,74	100 98,58
<b>IIR Train Test</b>	100 97,69	100 99,40	100 99,87	100 99,42	100 99,28	100 99,03	100 99,07	100 98,29	100 98,70	100 98,11	100 98,03	100 98,71
<b>Media Móvil Train Test</b>	100 97,17	100 99,21	100 99,55	100 99,15	100 99,28	100 98,78	100 98,57	100 98,17	100 98,65	100 98,77	100 97,59	100 98,39
<b>Smooth Train Test</b>	100 97,19	100 99,42	100 99,56	100 99,44	100 99,28	100 98,94	100 99,07	100 98,14	100 98,64	100 98,57	100 97,60	100 98,65
<b>Wavelet Train Test</b>	100 96,18	100 99,06	100 99,62	100 99,03	100 98,92	100 98,43	100 98,56	100 97,19	100 97,95	100 97,10	100 96,59	100 97,94
<b>Mediana Train Test</b>	100 96,70	100 99,32	100 81,88	100 99,17	100 99,55	100 98,76	100 98,68	100 97,92	100 98,86	100 98,29	100 97,02	100 98,34

Los resultados obtenidos probando los filtros FIR, media, smooth, IIR de la línea base, muestran similitud y una capacidad de detección de FV que puede considerarse aceptable. Con ellos, se puede separar de mejor manera la FV del resto de patologías cardíacas a la hora de realizar un diagnóstico. En vista de que los cuatros filtros son similares, se eligió el filtro IIR para la realización de las posteriores pruebas.

Las técnicas empleadas anteriormente manejan gran cantidad de datos MD de RTF de tamaño  $45 \times 150 = 6750$ , lo que aumenta la carga computacional y hace que el procesamiento se enlentezca y en ocasiones sea intratable. Por este motivo, se realizan pruebas que nos permitan reducir la dimensión de estos datos MD.

## 4.8 Clasificación por la conversión RTF a imagen IRTF

Con el fin de aumentar la velocidad de procesamiento y mejorar el rendimiento de detección de FV, se realiza una nueva técnica de análisis que consiste en crear un nuevo espacio de datos más reducido comparado con el espacio original.

Como fue explicado anteriormente en la tercera y cuarta etapa de las pruebas, cada RTF obtenida se las convirtió en IRTF, las cuales se registran cada una en una MD'' (no reducida).

Los resultados obtenidos mediante KNN usando la RTF e IRTF se encuentran en las tablas 10 y 11.

Luego se empleó la reducción de la dimensionalidad mediante dos formas; reducción del tamaño de IRTF y SC.

### 4.8.1 IRTF de tamaño reducido.

En esta prueba se reduce el tamaño de IRTF empleando cuatros técnicas (MIP, KNN, la técnica bilineal y la técnica bicúbica). Cada imagen quedó reducida al tamaño (3x5), por ser el tamaño apropiado y luego se convierte a MD'''.

Los datos de MD'', MD''' obtenidos mediante las representaciones de tipo IRTF e IRTF reducida, se introducen al clasificador KNN. Los resultados obtenidos para una sola iteración se muestran la figura 43.

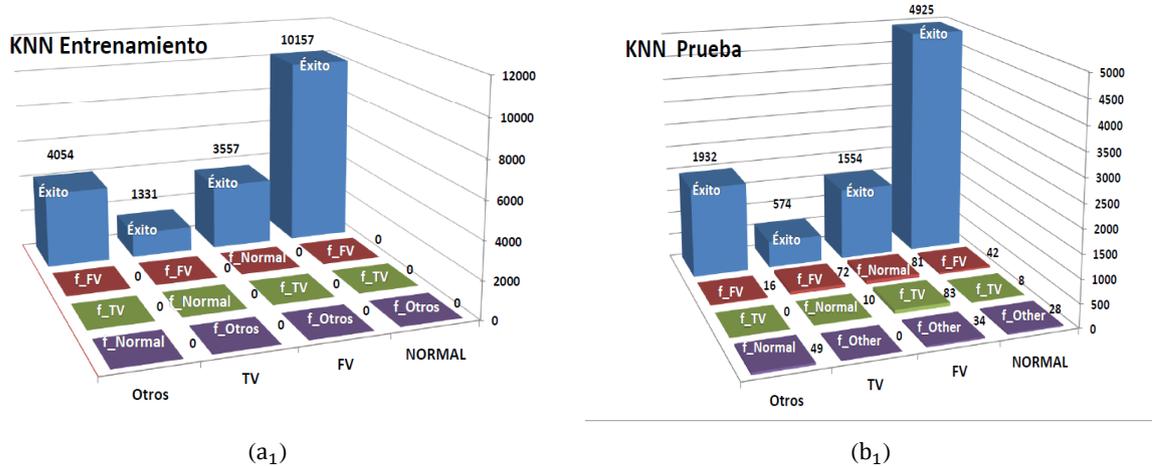


FIGURA 43. RESULTADOS PARA UNA ITERACIÓN DEL ENTRENAMIENTO Y LA PRUEBA DE UN CONJUNTO DE DATOS ASIGNADOS ALEATORIAMENTE MEDIANTE EL ALGORITMO KNN, USANDO LA TÉCNICA DE REDUCCIÓN DE DATOS MIP.

En la figura 43b<sub>1</sub> se aprecia los resultados obtenidos mediante KNN usando los datos de IRTF reducida (MIP). En la detección de clases, tenemos que ‘FV’ fue de 1554 ventanas detectadas como ‘FV’ y 198 ventanas detectadas como restantes de las clases. Así mismo en el caso ‘TV’ fueron 574 ventanas detectadas como ‘TV’ y 82 ventanas detectadas como otras clases. Además se observa como el nivel de confusión entre ‘FV’ y ‘TV’ resulta mayor comparado con los anteriores obtenidos mediante IRTF no reducida.

Las tablas 10 y 11 muestran los resultados alcanzados mediante algoritmo KNN para cada una de las pruebas usando los valores de sensibilidad, especificidad y exactitud para las cuatro clases.

Se realizaron comparaciones entre los valores de sensibilidad, especificidad y exactitud global de los resultados logrados en las respectivas clases para las tres técnicas, donde se puede ver que los valores de sensibilidad de las cuatro clases obtenidas por el clasificador empleando la matriz de RTF e IRTF 45x150, están por encima del 93%, que ofrecen buenos resultados y con una sensibilidad del (94,97%; 95,41%), una especificidad global del (99,27%; 99,25%) y una exactitud global del (98,47%; 98,53%) para ‘FV’ y una sensibilidad del (93,47%; 92,92%), especificidad global del (99,39%; 99,44%) y una exactitud global del (98,97 %; 98,98%) para ‘TV’, respectivamente.

TABLA 10. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD DE LA DETECCIÓN DE LAS PATOLOGÍAS ('FV', 'TV') OBTENIDOS POR EL ALGORITMO KNN, MEDIANTE LOS MÉTODOS RTF (45x150), IRTF DE TAMAÑOS (45x150, 3x5).

Clases		FV					TV						
Índices Estadísticos	Sens%	Esp%				Exa%	Sens%	Esp%				Exa%	
		Global	TV	Otros	Normal			Global	TV	Global	FV		Otros
Técnicas de clasificación		FV	Global	TV	Otros	Normal	Global	TV	Global	FV	Otros	Normal	Global
<b>RTF 45X150</b>													
Train		100	100	100	100	100	100	100	100	100	100	100	100
Test		94,97	99,27	95,21	99,63	99,66	98,47	93,47	99,39	96,98	99,99	99,98	98,97
<b>IRTF 45X150</b>													
Train		100	100	100	100	100	100	100	100	100	100	100	100
Test		95,41	99,25	94,51	99,65	99,71	98,53	92,92	99,44	97,23	100	99,99	98,98
IRTF reducida	<b>MIP</b>												
	Train	100	100	100	100	100	100	100	100	100	100	100	100
	Test	88,27	98,22	89,86	99,91	98,91	96,35	88,31	98,80	94,18	99,95	99,88	98,05
	<b>KNN</b>												
Train	100	100	100	100	100	100	100	100	100	100	100	100	
Test	73,84	96,31	88,12	97,97	96,71	92,01	83,34	97,98	89,86	99,86	99,72	96,88	
<b>Bilineal</b>													
Train	100	100	100	100	100	100	100	100	100	100	100	100	
Test	88	98,21	90,17	99,18	98,87	96,38	88,69	98,56	93,22	99,98	99,82	97,86	
<b>Bicúbica</b>													
Train	100	100	100	100	100	100	100	100	100	100	100	100	
Test	89,56	98,32	89,79	99,16	99,06	96,67	88,23	98,60	93,35	100	99,84	97,86	

TABLA 11. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD DE LA DETECCIÓN DE LAS PATOLOGÍAS ('NORMAL', 'OTROS') OBTENIDOS POR EL ALGORITMO KNN, MEDIANTE LOS MÉTODOS RTF(45x150), IRTF DE TAMAÑOS (45x150, 3x5).

Clases		Otros					Normal						
Índices Estadísticos	Sens%	Esp%				Exa%	Sens%	Esp%				Exa%	
		Otros	Global	TV	Normal			FV	Global	Normal	Global		FV
Técnicas de clasificación		Otros	Global	TV	Normal	FV	Global	Normal	Global	FV	TV	Otros	Global
<b>RTF 45X150</b>													
Train		100	100	100	100	100	100	100	100	100	100	100	100
Test		97,69	99,40	99,87	99,42	99,28	99,03	99,07	98,29	98,70	98,11	98,03	98,71
<b>IRTF 45X150</b>													
Train		100	100	100	100	100	100	100	100	100	100	100	100
Test		97,71	99,50	99,93	99,50	99,34	99,11	99,20	98,34	98,70	98,30	98,04	98,80
IRTF reducida	<b>MIP</b>												
	Train	100	100	100	100	100	100	100	100	100	100	100	100
	Test	96,91	99,06	99,87	99,28	97,93	98,59	98,14	96,82	95,20	98,20	97,70	97,53
	<b>KNN</b>												
Train	100	100	100	100	100	100	100	100	100	100	100	100	
Test	93,61	96,82	100	97,41	93,97	96,09	94,03	91,50	84,95	94,96	95,59	92,90	
<b>Bilineal</b>													
Train	100	100	100	100	100	100	100	100	100	100	100	100	
Test	96,95	99,13	99,93	99,35	98,16	98,65	98,06	97,26	96,3	98,24	97,75	97,70	
<b>Bicúbica</b>													
Train	100	100	100	100	100	100	100	100	100	100	100	100	
Test	97,13	99,31	99,86	99,45	98,68	98,83	98,40	97,57	96,91	98,20	97,93	98,02	

En el caso de IRTF reducida 3x5 al utilizar las cuatro técnicas (la media de la intensidad de los píxeles, KNN, la técnica bilineal y la técnica bicúbica), se obtiene una sensibilidad del (88,27%; 73,84%; 88%; 89,56 %), una especificidad global del (98,22%; 96,31 %; 98,21 %; 98,32%), y una exactitud global del (96,35 %; 92,01%; 96,38%; 96,67%) para 'FV'. Para 'TV' se muestra una sensibilidad del (88,31%; 83,34%; 88,69%; 88,23%) especificidad global del (98,8%; 97,98 %; 98,56%; 98,6%) y una exactitud global del (98,05%; 96,88%; 97,86%; 97,86%) respectivamente.

La tabla 12 muestra el tiempo de ejecución medio de todo el proceso de cálculo obtenido para cada ventana  $V_t$  de la señal ECG. Se aprecia que el clasificador con entrada de datos IRTF de tamaño reducido para las cuatro pruebas tiene un tiempo de ejecución  $t = (0,024s; 0,019s; 0,017s; 0,017s)$  respectivamente. También se observa unos tiempos  $t = 0,176s$  y  $t = 0,1682s$  obtenidos por RTF e IRTF no reducida respectivamente.

TABLA 12. RESULTADOS DE TIEMPO DE EJECUCION MEDIO PARA CADA VENTANA DE TIEMPO, OBTENIDOS POR EL ALGORITMO DE CLASIFICACIÓN KNN MEDIANTE LOS MÉTODOS RTF(45x150), IRTF DE TAMAÑOS (45x150, 3x5).

Técnicas:	RTF	IRTF no reducida	IRTF reducida			
			MIP	KNN	Bilineal	Bicúbica
Tiempo de ejecución (s)	0,1763	0,1682	0,024	0,019	0,017	0,017

#### 4.8.2 Selección de características

Esta parte del trabajo consiste en usar un nuevo subconjunto de características  $V_{sc}$  de tamaño reducido donde  $NC = \{100, 50, 25, 15\}$  píxeles, como entrada del clasificador KNN, con el propósito de mejorar la detección de FV en tiempo real.

Una vez obtenidos los subconjuntos  $MD_i$  con  $i = \{1, 2, 3\}$ , del mismo modo como se describe en la sección 4.4 para clasificación, se aplica SC a cada uno de las pares con el objetivo de seleccionar un conjunto de características significativas, obteniendo nuevos conjunto de datos  $V_{sci}$   $V_{sci}$  con  $i = \{1, 2, 3\}$  respectivamente. De cada uno de los datos  $MD_i$ , se usa el 67% como entrenamiento y el resto como test.

**Etapas de entrenamiento:** consiste en crear la Función de Predicción  $FP_i$  que corresponden a cada uno de los  $V_{SCi}$  y posteriormente ser utilizados para evaluar nuevos datos introducidos al clasificador KNN.

**Etapas de la prueba:** el 33% restante de los datos se usan como test, empleando las tres funciones de predicción obtenidas en la segunda etapa, como se muestra en la figura 44.

Repetiendo todo las etapas del proceso para cada valor de NC.

Los resultados para una sola iteración de los aciertos y errores de las clases ('FV', 'TV', 'Otros', 'Normal') mediante el clasificador KNN usando la reducción de datos realizados por medio de SC en el ejemplo con  $NC = \{15, 100\}$  se muestran en la figura 45.

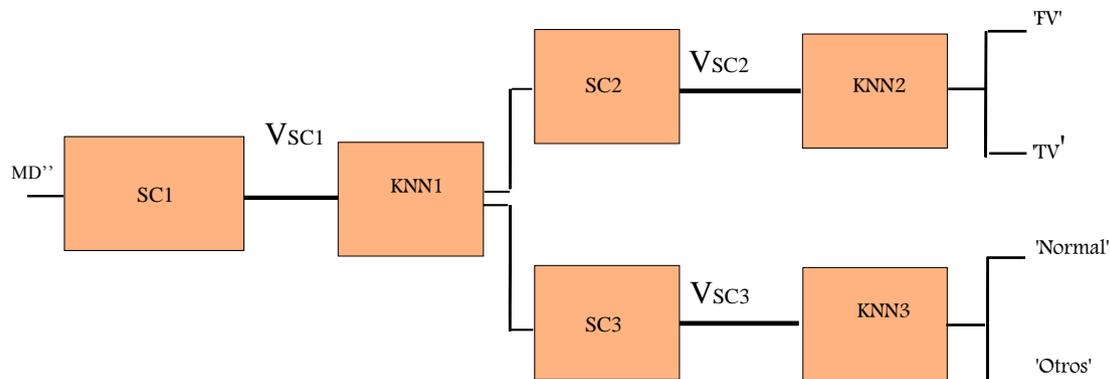


FIGURA 44. FASE DE LA PRUEBA MEDIANTE LA TÉCNICA SC.

La figura 45a muestra los resultados obtenidos mediante KNN usando los datos reducidos  $V_{SC}$  con  $NC = \{15, 100\}$ . Al tomar  $NC=15$ , la detección de clases 'FV' fueron clasificadas 1362 ventanas como 'FV', 119 ventanas como 'TV', 187 ventanas como 'Normal' y 84 ventanas como 'Otros', así para 'TV' fueron clasificadas 563 ventanas como 'TV', 76 ventanas como 'FV' y 17 ventanas como 'Normal'. Al contrario al tomar  $NC=100$ , se observa que para la clase 'FV' fueron clasificados 1629 ventanas como 'FV', 68 ventanas como 'TV', 31 ventanas como 'Normal' y 24 ventanas como 'Otros', así mismo la clase 'TV' fueron clasificados 595 ventanas como 'TV', 51 ventanas como 'FV' y 10 ventanas como 'Normal', también puede ver que el nivel de errores de 'FV' y 'TV' es menor para 'Normal', se entiende que 'Normal' es una clase bien definida con un bajo nivel de dispersión.

En el proceso de evaluación de los resultados alcanzados mediante el algoritmo con SC, se calculó sensibilidad, especificidad y exactitud para cada tipo de clase. Estos resultados se resumen en las tablas 13 y 14.

Los resultados de las pruebas se muestran en la tabla 13, en ésta la discriminación entre FV y TV parece clara alcanzando unos niveles superiores de 88 % para NC=100 y NC=50.

Se obtiene una sensibilidad del (92,18%; 88,58%), una especificidad global del (98,90%, 98,74%), y una exactitud global del (97,64%; 96,82%) para 'FV'. Para 'TV' se muestra una sensibilidad del (91,01%; 90,09%), especificidad global del (99,24%; 99,06%) y una exactitud global del (98,66%; 98,41%) respectivamente.

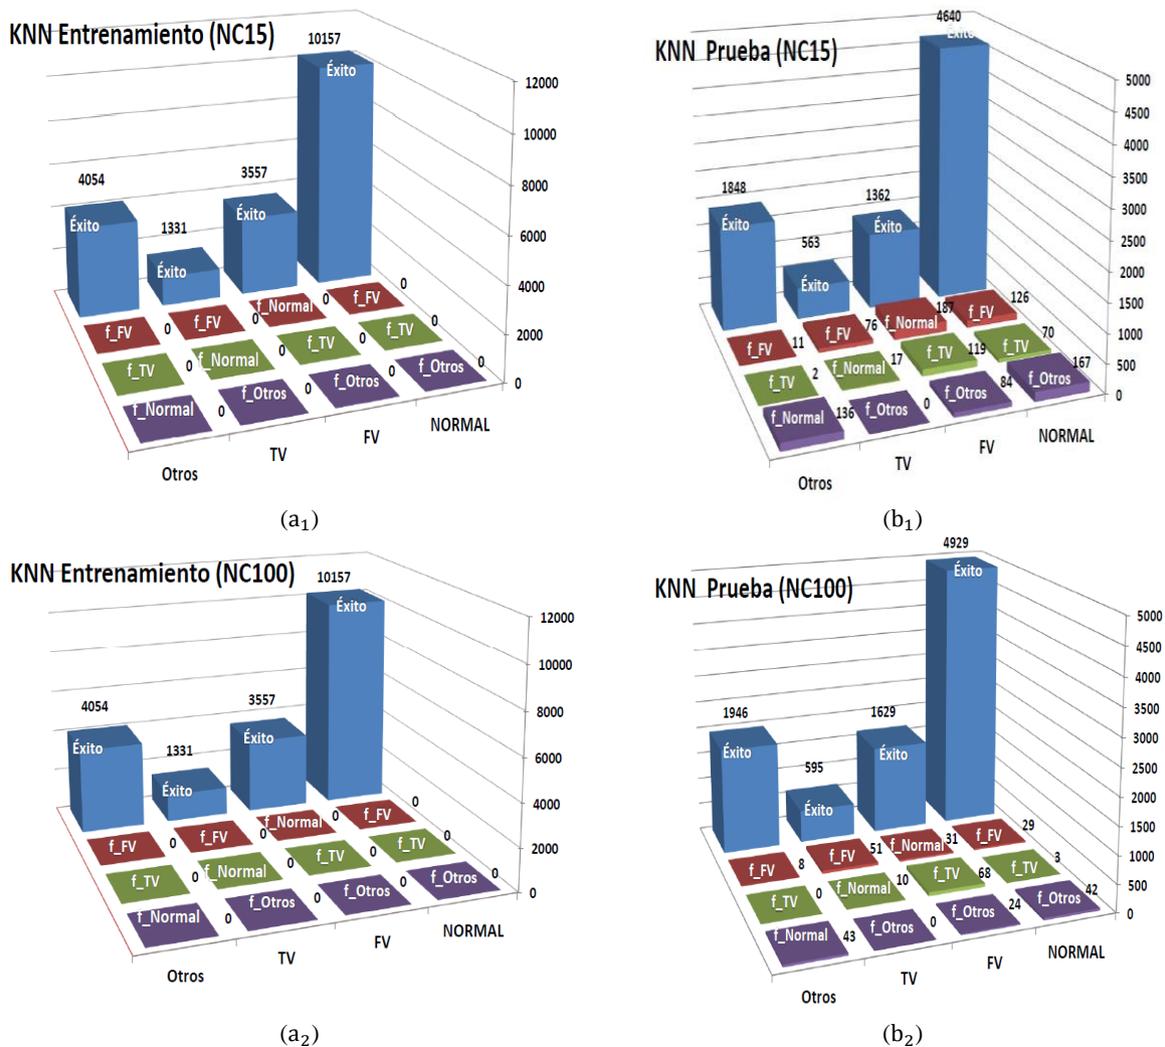


FIGURA 45. RESULTADOS PARA UNA ITERACIÓN DEL ENTRENAMIENTO Y LA PRUEBA DE UN CONJUNTO DE DATOS ASIGNADOS ALEATORIAMENTE MEDIANTE EL ALGORITMOS KNN, USANDO LA TÉCNICA DE REDUCCIÓN SC.

TABLA 13. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD DE LA DETECCIÓN DE LAS PATOLOGÍAS ('FV', 'TV') OBTENIDOS POR EL ALGORITMO KNN, MEDIANTE LOS MÉTODOS SC DE DIFERENTE TAMAÑOS NC={15, 25, 50, 100}.

Clases	FV						TV					
Índices Estadísticos	Sens%	Esp%				Exa%	Sens%	Esp%				Exa%
SC	FV	Global	TV	Otros	Normal	Global	TV	Global	FV	Otros	Normal	Global
<b>NC=100</b>												
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100
<b>Test</b>	92,18	98,90	99,85	99,48	97,64	97,64	91,01	99,24	96,13	100	100	98,66
<b>NC=50</b>												
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100
<b>Test</b>	88,58	98,74	91,49	99,74	99,29	96,82	90,09	99,06	95,51	99,95	99,88	98,41
<b>NC=25</b>												
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100
<b>Test</b>	79,39	97,39	86,59	99,32	98,04	93,94	83,69	98,31	93,73	100	99,66	97,23
<b>NC=15</b>												
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100
<b>Test</b>	76,66	97,33	87,05	99,41	97,88	93,31	83,99	97,52	91,30	99,89	98,52	96,50

TABLA 14. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD DE LA DETECCIÓN DE LAS PATOLOGÍAS ('NORMAL', 'OTROS') OBTENIDOS POR EL ALGORITMO KNN, MEDIANTE LOS MÉTODOS SC DE DIFERENTE TAMAÑOS NC={15, 25, 50, 100}.

Clases	Otros						Normal					
Índices Estadísticos	Sens%	Esp%				Exa%	Sens%	Esp%				Exa%
SC	Otros	Global	TV	Normal	FV	Global	Normal	Global	FV	TV	Otros	Global
<b>NC=100</b>												
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100
<b>Test</b>	99,45	99,09	99,87	99,24	98,36	98,73	98,72	97,72	97,29	99,33	97,59	98,26
<b>NC=50</b>												
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100
<b>Test</b>	97,05	98,52	99,66	98,87	97	98,20	98,06	96,68	95,16	98,66	97,34	97,43
<b>NC=25</b>												
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100
<b>Test</b>	97,59	96,51	99,10	97,59	92,06	96,30	94,86	94,13	90,38	97,00	96,22	94,54
<b>NC=15</b>												
<b>Train</b>	100	100	100	100	100	100	100	100	100	100	100	100
<b>Test</b>	92,89	96,03	99,28	96,50	93,20	95,32	95,32	91,20	91,89	96,67	93,50	92,61

En el caso de NC=25 NC=15 obtenidos con la reducción, los resultados son inferiores, con una sensibilidad del (79,39%; 76,66%), una especificidad global del (97,39%; 97,33%), y una exactitud global del (93,94%; 93,31%) para 'FV'. Para 'TV' se muestra una sensibilidad del (83,69%; 83,99%) especificidad global del (98,31%; 97,52%), y una exactitud global del (97,23%; 96,50%) respectivamente.

Se muestra el tiempo de ejecución medio de todo el proceso de cálculo obtenido para cada ventana  $V_t$  de la señal ECG, empleando las cuatro pruebas de  $NC=\{15, 25, 50, 100\}$  donde  $t=(0,0493s; 0,0497s; 0,0505s; 0,0523s)$  respectivamente. También se observa unos tiempos  $t = 0,1763s$  y  $t = 0,1682s$  obtenidos por RTF e IRTF no reducida respectivamente como se observa en la tabla 15. Se aprecia que al utilizar  $NC=50$ , se obtiene mejores resultados en tiempo y detección de FV.

TABLA 15. RESULTADOS DE TIEMPO DE EJECUCIÓN MEDIO PARA CADA VENTANA DE TIEMPO, OBTENIDOS POR EL ALGORITMO DE CLASIFICACION KNN, MEDIANTE LOS MÉTODOS SC DE DIFERENTE TAMAÑOS  $NC=\{15,25,50,100\}$ .

Técnicas:	RTF	IRTF no reducida	SC			
			NC=15	NC=25	NC=50	NC=100
Tiempo de ejecución (s)	0,1763	0,1682	0,0493	0,0497	0,0505	0,0523

*El siguiente capítulo está organizado de la siguiente manera: en la sección 1 y 2 se realiza una introducción sobre combinación de los clasificadores. Se explica brevemente el concepto de algunos de los métodos más utilizados. En la sección 2 se realiza un estudio comparativo de los diferentes tipos de estrategias de clasificación combinados a fin de mejorar la detección de la FV.*

## Capítulo 5. Métodos de clasificación combinados

Actualmente no existe un esquema general acerca de qué método de clasificación es el más apropiado para la detección de cualquier tipo de patología cardíaca. La combinación de clasificadores (multclasificadores) [137] se ha dado a conocer como una nueva técnica para mejorar el desempeño de los clasificadores individuales, se basa en construir un clasificador a partir de un conjunto de clasificadores que puede otorgar información interesante sobre la representación de los datos en comparación con los resultados alcanzados utilizando clasificadores individuales.

Existe mucha literatura en la que se ha usado la combinación de clasificadores dirigidos a las investigaciones bioinformáticas y biomédicas, análisis geofísicos y teledetección, entre otros. De los multclasificadores más utilizados tenemos Random Forests, Bagging, Boosting o Random Subspaces. En el caso de los Random Subspaces [138] se utilizan diferentes subconjuntos de atributos para entrenar cada clasificador individual. En el tipo Bagging [62] la variedad proviene de usar distintos subconjuntos de instancias para entrenar cada clasificador individual. Los Random Forests [139] es una modificación sustancial de bagging que emplean Random Trees como clasificadores individuales.

El tipo Boosting [140] entrena de forma iterativa los clasificadores individuales, por lo tanto, modifica los pesos de las instancias que va a emplear el siguiente clasificador individual. Existen otros métodos como Cascading [141], Stacking [142] y Grading [143].

La combinación de clasificadores puede ser de dos tipos: Fusión de Clasificadores y Selección de Clasificadores. En el primer tipo se usan todos los clasificadores en cada una de las muestras, mientras que en el segundo tipo se selecciona el algoritmo de clasificación según la muestra.

A continuación se describen las topologías de combinación.

## 5.1 Las topologías de combinación

Las topologías de combinación de clasificadores empleadas en este trabajo de investigación, se pueden dividir en tres categorías cascadas, paralelas y jerárquicas.

En el método de topología en cascada, los resultados obtenidos por cada clasificador individual representan la entrada en el siguiente clasificador, hasta que la decisión final es alcanzada por el clasificador al terminar la serie como se observa en la figura 46.

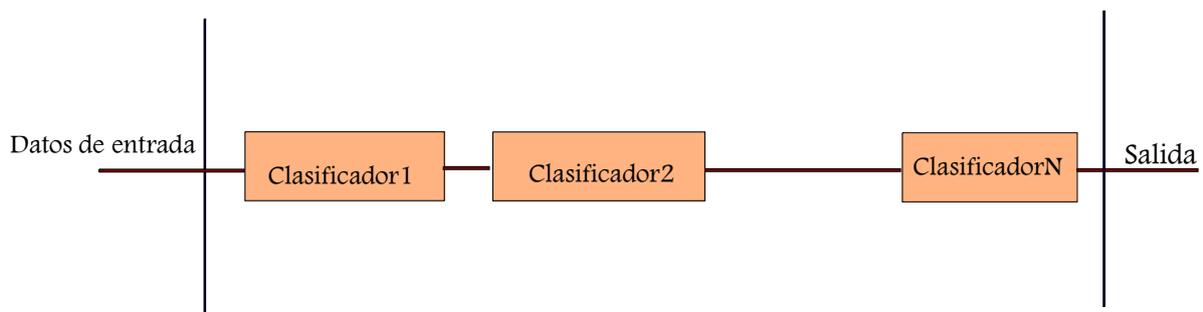


FIGURA 46. MÉTODO DE CLASIFICADORES COMBINADOS EN CASCADA

El método de topología en paralelo es el más frecuente en combinación de clasificadores. Todos los clasificadores se ejecutan paralelamente utilizando los mismos datos de entrada, y los resultados alcanzados por todos los clasificadores {clasificador1(cl1), clasificador2(cl2), clasificador3(cl3)...clasificadorN(clN)} generan un resultado multclasificador que llamaremos cl1\_cl2\_...\_clN que se combinan con el objetivo de obtener una decisión adecuada mediante una regla de combinación como puede ser el método de votación [137] como se muestra en la figura 47.

Esta metodología tiene un alto tiempo de ejecución ya que todos los algoritmos de clasificaciones se deben ejecutar para tomar la decisión final.

El método de votación funciona de igual manera que el ser humano al votar en las elecciones políticas. En otras palabras dependiendo del número de votos alcanzados a favor de cada clase se asigna a la que obtenga mayoría y los empates se resuelven aleatoriamente.

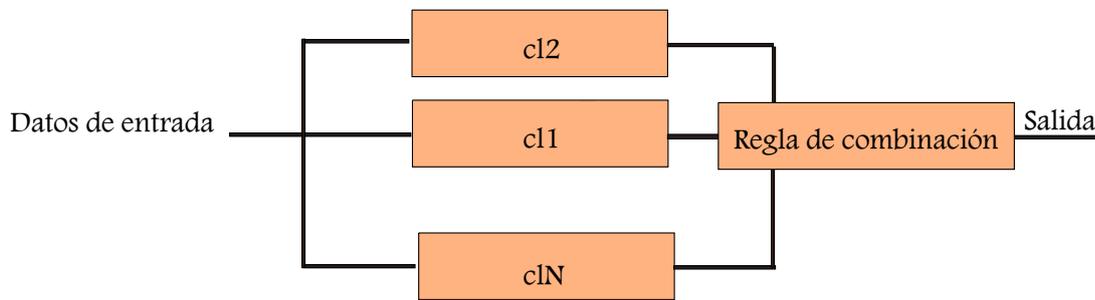


FIGURA 47. MÉTODO MULTICLASIFICADOR DE FUSIÓN EN PARALELO.

En la topología de jerárquica se combinan topologías en paralelo y cascada. Al juntar estas dos se puede obtener mejor resultado que el alcanzado al emplear los clasificadores en forma individual. Cada clasificador (c11, c12, c13) utiliza como entrada ('FVTV', 'NormalOtros'), ('FV', 'TV') y ('Otros', 'Normal') respectivamente. Al unir los clasificadores se genera un algoritmo multclasificador que llamaremos c11\_c12\_c13. En la figura 48 se puede apreciar la estructura seguida.

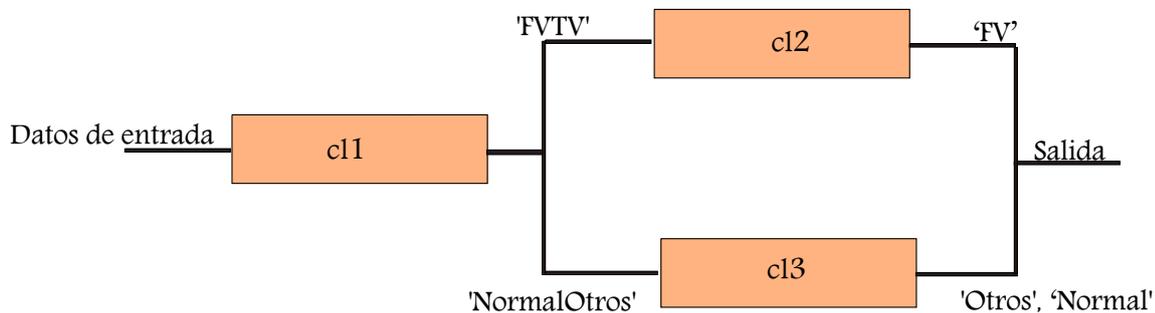


FIGURA 48. TOPOLOGÍA DE MULTICLASIFICADOR DE JERÁRQUICA.

## 5.2 Estudio comparativo de los diferentes métodos de clasificación combinados

En este apartado se muestran y discuten los resultados obtenidos por combinación de Método de Mayoría de Votos (MMV) y Método de Jerárquica (MJ) descritos anteriormente.

En las pruebas de clasificación a realizar, se muestran cómo se comportan la combinación de los algoritmos de clasificación al aplicarse sobre un mismo conjunto de datos (IRTF, IRTF no reducida, SC), en relación a los resultados obtenidos en el capítulo anterior utilizando clasificadores individuales. Se compara respecto a KNN que resultó ser el mejor por su discriminación entre 'FV' y 'TV'.

El esquema propuesto está basado en tres pruebas que se describen a continuación.

### 5.2.1 Prueba usando los datos IRTF no reducida.

Se realiza usando los datos de IRTF no reducidas, como entrada para las estrategias MMV y MJ con el fin de comprobar el comportamiento de las combinaciones entre los clasificadores ANNC, BAGG, L2\_RLR, SSVM y KNN e individualmente.

#### Método de mayoría de votos

En el primer análisis, se aplica el MMV usando tres algoritmos de clasificación individuales, los resultados obtenidos se muestran en las tablas 16 y 17.

Al analizar los resultados de las tablas 16, 17 y 18, se puede apreciar que al utilizar MMV, las combinaciones ANNC\_SSVM\_BAGG y ANNC\_KNN\_BAGG obtuvieron los mejores resultados, con una sensibilidad del 97,89%; 98,46% y una especificidad global del 98,96%; 98,98% para 'FV'. Para 'TV' una sensibilidad del 89,94%; 89,63% y una especificidad global del 99,79%; 99,86%, respectivamente.

Además una sensibilidad del 99,32%; 99,52% y una especificidad global del 97,94%; 98,29% para 'Normal'. Para 'Otros' se tiene una sensibilidad del 96,54%, 97,20%, una especificidad global del 97,73%; 99,84% y un tiempo de ejecución de  $t = 0,096s; 0,2961s$  respectivamente.

TABLA 16. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD GLOBAL Y EXACTITUD GLOBAL DE LA DETECCIÓN DE LAS PATOLOGÍAS ('FV', 'TV') OBTENIDOS POR EL MÉTODO MULTICLASIFICADORES MMV, USANDO LOS DATOS DE IRTF NO REDUCIDA.

Clases Combinación de los algoritmos (c1,c2,c3)	FV			TV		
	Sens%	Esp%	Exa%	Sens%	Esp%	Exa%
ANNC_SSVM_BAGG	97,89	98,96	98,76	89,94	99,79	99,10
ANNC_SSVM_L2_RLR	95,03	98,71	98,01	87,96	99,40	98,59
ANNC_BAGG_L2_RLR	97,89	98,84	98,66	87,80	99,88	99,98
BAGG_L2_RLR_SSVM	95,61	98,63	98,06	87,04	99,52	98,63
ANNC_KNN_BAGG	98,46	98,98	98,89	89,63	99,86	99,14

TABLA 17. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD GLOBAL Y EXACTITUD GLOBAL DE LA DETECCIÓN DE LAS PATOLOGÍAS (‘OTROS’, ‘NORMAL’) OBTENIDOS POR EL MÉTODO MULTICLASIFICADOR MMV, USANDO LOS DATOS DE IRTF NO REDUCIDA.

Clases Combinación de los algoritmos (cl1,cl2,cl3)	Otros			Normal		
	Sens %	Esp %	Exa %	Sens %	Esp %	Exa %
ANNC_SSVM_BAGG	96,54	99,73	99,04	99,32	97,94	98,68
ANNC_S SVM_L2_RLR	96,19	99,02	98,41	98,18	97,33	97,79
ANNC_BAGG_L2_RLR	96,54	99,74	99,05	99,38	97,68	98,59
BAGG_L2_RLR_SSVM	96,14	99,03	98,41	98,22	97,34	97,81
ANNC_KNN_BAGG	97,20	99,84	99,27	99,52	98,29	98,95

En los dos casos se observa que la detección de FV ha mejorado significativamente, sin embargo la detección de TV ha disminuido, esto es debido a la similitud entre FV y TV al compararla con lo que ha obtenido mediante algoritmos KNN.

Se concluye que las combinaciones no superan los resultados obtenidos en el caso de KNN. Además, la combinación requirió más tiempo de cómputo que la requerida por un algoritmo individual KNN.

TABLA 18. RESULTADOS DE TIEMPO DE EJECUCIÓN MEDIO PARA CADA VENTANA DE TIEMPO, OBTENIDOS POR EL MÉTODO MULTICLASIFICADOR DE MMV, USANDO LOS DATOS DE IRTF NO REDUCIDA.

Combinación de los algoritmos (cl1,cl2,cl3)	Tiempo de ejecución (s)
ANNC_SSVM_BAGG	0,0961
ANNC_S SVM_L2_RLR	0,0493
ANNC_BAGG_L2_RLR	0,0962
BAGG_L2_RLR_SSVM	0,0957
ANNC_KNN_BAGG	0,2961

### Método de jerárquica

En el segundo análisis, se aplica MJ a los tres algoritmos individuales (c11, c12, c13) se obtiene un multclasificador c11\_c12\_c13 ver figura 48, los resultados obtenidos se muestran en las tablas 19 y 20.

Dado que KNN fue el mejor algoritmo en la detección y discriminación entre FV y TV, se lo eligió en esta estrategia como c12. Se observa que KNN obtiene una alta exactitud, sin embargo tiene un tiempo de ejecución más alto debido a que el algoritmo KNN requiere de muchas iteraciones para calcular las distancias más cercanas. En esta investigación, se quiere lograr una detección más rápida de las arritmias combinando otros algoritmos, por lo cual se toma los clasificadores {c11, c13} que contienen SSVM, ANNC, L2\_RLR. La predicción de SSVM sólo necesita calcular el producto entre el vector de pesos y el vector de parámetros donde el tiempo de ejecución es menor. En los algoritmos ANNC se separan las clases por medio de una superficie que maximice el margen entre ellas, con el menor número de errores de entrenamiento, teniendo un costo computacional mucho menor que lo obtenido por KNN. El algoritmo L2\_RLR tiene menor tiempo de ejecución dado que se basa en probabilidades. El sistema Bagging crea sus clasificadores individuales entrenando un sistema de clasificación sobre diferentes muestras bootstrap del conjunto de entrenamiento con lo que se tiene un tiempo de ejecución más alto que el resto de los clasificadores excepto KNN.

Con el fin de verificar el comportamiento de los multclasificadores, se han probado los algoritmos ANNC, BAGG, L2\_RLR como c11 para la discriminación entre las clases ‘FVTV’ y ‘NormalOtros’ y se usa los algoritmos ANNC y L2\_RLR como c13 para la discriminación entre la clase ‘Normal’ y ‘Otros’.

Analizando los resultados mostrando en las tablas 19, 20 y 21, se observa que los valores de la sensibilidad de ‘Otros’ y ‘Normal’ son superiores al 94%.

Se puede observar que las combinaciones ANNC\_KNN\_ ANNC y ANNC\_KNN\_ L2\_RLR dieron los mejor resultados al clasificar ‘FV’ y ‘TV’, presentando una sensibilidad del 95,13% 94,89% y especificidad del 99,1% 99,08% para ‘FV’. También para ‘TV’ una sensibilidad del 92,32% 92,37% y especificidad del 99,33% 99,27% respectivamente, con un tiempo de ejecución entre [0,0491s; 0,1016s], [0,0489s; 0,1006s] respectivamente.

TABLA 19. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD GLOBAL Y EXACTITUD GLOBAL DE LA DETECCIÓN DE LAS PATOLOGÍAS (‘FV’, ‘TV’) OBTENIDOS POR EL ALGORITMO DE COMBINACION MJ, USANDO LOS DATOS DE IRTF NO REDUCIDA.

Clases Combinación de los algoritmos (c1,c2,c3)	FV			TV		
	Sens %	Esp %	Exa %	Sens %	Esp %	Exa %
ANNC_KNN_ANNC	95,13	99,1	98,41	92,32	99,33	98,9
ANNC_KNN_L2_RLR	94,89	99,08	98,3	92,37	99,27	98,78
BAGG_KNN_ANNC	95,58	99,31	98,6	94,02	99,31	99,14
BAGG_KNN_L2_RLR	95,58	99,31	98,6	94,02	99,31	99,14
L2_RLR_KNN_ANNC	93,33	98,93	97,88	92,01	99,22	98,71
L2_RLR_KNN_L2_RLR	93,54	98,01	97,98	92,95	99,26	98,82
KNN	95,41	99,25	98,53	92,92	99,44	98,98

TABLA 20. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD GLOBAL Y EXACTITUD GLOBAL DE LA DETECCIÓN DE LAS PATOLOGÍAS (‘OTROS’, ‘NORMAL’) OBTENIDOS POR EL ALGORITMO DE COMBINACION MJ, USANDO LOS DATOS DE IRTF NO REDUCIDA.

Clases Combinación de los algoritmos (c1,c2,c3)	Otros			Normal		
	Sens%	Esp%	Exa%	Sens%	Esp%	Exa%
ANNC_KNN_ANNC	97,22	99,57	99,06	99,04	98,1	98,61
ANNC_KNN_L2_RLR	96,11	99,18	98,45	98,42	97,67	98,17
BAGG_KNN_ANNC	97,42	99,52	99,07	99,02	98,36	98,72
BAGG_KNN_L2_RLR	96,92	98,92	98,28	98,22	97,73	97,99
L2_RLR_KNN_ANNC	97,2	99,5	99	98,61	97,39	98,05
L2_RLR_KNN_L2_RLR	95,71	98,84	98,16	97,81	96,89	97,38
KNN	97,71	99,50	99,11	99,20	98,34	98,80

De estos resultados, se puede concluir que los algoritmos de combinación tienen un comportamiento similar que KNN en la detección de FV en conjuntos de datos muy grandes y con alta dimensionalidad, y además su tiempo de ejecución es reducido significativamente.

TABLA 21. RESULTADOS DE TIEMPO DE EJECUCIÓN MEDIO PARA CADA VENTANA DE TIEMPO, OBTENIDOS POR EL ALGORITMO DE COMBINACION MJ, USANDO LOS DATOS DE IRTF NO REDUCIDA.

Combinación de los algoritmos (c1,c2,c3)	Clasificador	
	Tiempo de ejecución (s)	
	Min	Max
ANNC_KNN_ANNC	0,0491	0,1016
ANNC_KNN_L2_RLR	0,0489	0,1006
BAGG_KNN_ANNC	0,0686	0,1156
BAGG_KNN_L2_RLR	0,0676	0,1076
L2_RLR_KNN_ANNC	0,0488	0,0876
L2_RLR_KNN_L2_RLR	0,0487	0,1356
KNN	0,1682	

## 5.2.2 Pruebas usando los datos IRTF reducida

Lo mismo que la prueba anterior, se utiliza MJ. En este caso se aplican los datos de IRTF reducidas (MIP) y SC, para comprobar como las combinaciones se comportan entre ellas.

### 5.2.2.1 Pruebas usando MIP

En esta prueba los resultados se obtienen al realizar combinaciones entre los clasificadores individuales mediante MJ usando los datos de IRTF reducida mediante MIP.

Analizando los resultados ofrecidos por los diferentes algoritmos de combinación propuestos en las tablas 22, 23 y 24, se observa que los resultados son buenos y similares en la detección de FV y TV. Sin embargo, son peores cuando se usa el algoritmo L2\_RLR como c13. Mientras cuando se usan los algoritmos ANNC y BAGG como c13 se obtienes valores muy similares. El tiempo de ejecución es más rápido cuando se usa ANNC. Se puede concluir que, en cuanto al tiempo de ejecución, los mejores resultados se encontraron con las configuraciones de multclasificador que empleaban ANNC\_KNN\_ANNC.

TABLA 22. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD GLOBAL Y EXACTITUD GLOBAL DE LA DETECCIÓN DE LAS PATOLOGÍAS ('FV', 'TV') OBTENIDOS POR EL ALGORITMO DE COMBINACION MJ , USANDO LOS DATOS DE IRTF REDUCIDA MEDIANTE MIP.

Clases	FV			TV		
Combinación de los algoritmos (c1,c2,c3)	Sens%	Esp%	Exa%	Sens%	Esp%	Exa%
ANNC_KNN_ANNC	92,14	98,07	97,07	89,02	80,78	98,08
ANNC_KNN_L2RLR	92,14	97,96	96,74	89,02	98,63	97,87
ANNC_KNN_BAGG	92,14	98,21	97,07	89,02	98,78	98,08
BAGG_KNN_ANNC	91,64	98,41	97,13	89,08	98,99	98,09
BAGG_KNN_BAGG	91,64	98,41	97,13	89,08	98,79	98,1
KNN	88,27	98,22	96,35	88,31	98,80	98,05

TABLA 23. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD GLOBAL Y EXACTITUD GLOBAL DE LA DETECCIÓN DE LAS PATOLOGÍAS ('OTROS', 'NORMAL') OBTENIDOS POR EL ALGORITMO DE COMBINACION MJ, USANDO LOS DATOS DE IRTF REDUCIDA MEDIANTE MIP.

Clases	Otros			Normal		
Combinación de los algoritmos (c1,c2,c3)	Sens %	Esp %	Exa %	Sens %	Esp %	Exa %
ANNC_KNN_ANNC	95,59	99,5	98,65	98,31	97,46	97,92
ANNC_KNN_L2RLR	66,83	94,63	88,56	91,46	83,95	88,03
ANNC_KNN_BAGG	95,16	99,86	98,83	98,68	97,09	97,95
BAGG_KNN_ANNC	95,84	99,42	98,64	98,36	97,19	97,83
BAGG_KNN_BAGG	95,39	99,39	98,84	98,72	96,76	97,82
KNN	96,91	99,06	98,59	98,14	96,82	97,53

Es remarcable que estos resultados fuesen mejores que los obtenidos con otras aproximaciones computacionalmente más costosas, como KNN.

TABLA 24. RESULTADOS DE TIEMPO DE EJECUCIÓN MEDIO PARA CADA VENTANA DE TIEMPO, OBTENIDOS POR EL ALGORITMO DE COMBINACION MJ, USANDO LOS DATOS DE IRTF REDUCIDA MEDIANTE MIP.

Combinación de los algoritmos (c1,c2,c3)	Tiempo de ejecución (s)	
	Min	Max
ANNC_KNN_ANNC	0,0239	0,0241
ANNC_KNN_L2RLR	0,0239	0,0241
ANNC_KNN_BAGG	0,0241	0,0248
BAGG_KNN_ANNC	0,0240	0,0248
BAGG_KNN_BAGG	0,0240	0,0256
KNN	0,0246	

### 5.2.2.2 Pruebas usando SC

En esta prueba los resultados se obtienen al realizar combinaciones entre los clasificadores individuales mediante MJ usando los datos reducidos SC (N=50). Los resultados obtenidos aprecian en las tablas 25,26 y 27.

Analizando los resultados ofrecidos por los diferentes algoritmos de combinación propuestos en las tablas 25, 26 y 27 se observa que la mayoría de los algoritmos combinados obtienen valores de sensibilidad y especificidad superior al 89%, sin embargo, cuando se usa BAGG combinado con KNN el tiempo de ejecución superan  $4,810^{-3}$ s. Del resto de las combinaciones, los que presentan peores resultados son ANNC\_KNN\_L2\_RLR y BAGG\_KNN\_L2\_RLR con una sensibilidad del 77,81%, 77,66% respectivamente para la clase ‘Otros’, y la sensibilidad del resto de las clases supera el 89%.

Del mismo modo, se puede notar que siempre la separación entre ‘FV’ y ‘TV’ son valores superiores al 88%; esto depende por un lado del clasificador que estamos usando como c12 que es en este caso KNN, y por otro lado depende del clasificador que es usado como calificador c11 para separar las clases ‘NormalOtros’ y ‘FVTV’.

Se observó que, al utilizar ANNC\_KNN\_ANNC se obtuvo mayor precisión, con una sensibilidad del 92,6% y especificidad del 98,68% para ‘FV’, una sensibilidad del 89,3%, una especificidad del 99,01% para ‘TV’ y un tiempo de ejecución entre [0,0487s; 0,0492s]

superando en un 4% la sensibilidad de FV que lo logrado con el algoritmo KNN individual usando los mismo datos.

TABLA 25. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD GLOBAL Y EXACTITUD GLOBAL DE LA DETECCIÓN DE LAS PATOLOGÍAS (‘FV’, ‘TV’) OBTENIDOS POR EL ALGORITMO DE COMBINACION MJ, USANDO SC.

Clases	FV			TV		
	Sens %	Esp %	Exa %	Sens %	Esp %	Exa %
ANNC_KNN_ANNC	92,6	98,68	97,52	89,3	99,01	98,32
ANNC_KNN_L2RLR	92,41	98,52	97,27	89,27	98,95	98,2
ANNC_KNN_BAGG	92,6	98,68	97,53	89,3	99,01	98,31
BAGG_KNN_ANNC	91	98,17	96,81	90,39	98,91	98,29
BAGG_KNN_L2RLR	91	97,99	96,56	90,39	98,81	98,16
BAGG_KNN_BAGG	90,51	98,17	96,81	90,39	98,91	98,29
KNN_KNN_KNN	88,58	98,74	91,49	90,09	99,06	95,51

TABLA 26. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD GLOBAL Y EXACTITUD GLOBAL DE LA DETECCIÓN DE LAS PATOLOGÍAS (‘OTROS’, ‘NORMAL’) OBTENIDOS POR EL ALGORITMO DE COMBINACION MJ, USANDO SC.

Clases	Otros			Normal		
	Sens %	Esp %	Exa %	Sens %	Esp %	Exa %
ANNC_KNN_ANNC	94,52	99,25	98,22	98,28	96,27	97,36
ANNC_KNN_L2RLR	77,81	94,55	90,9	91,61	88,43	90,15
ANNC_KNN_BAGG	92,75	99,87	98,32	99	95,24	97,27
BAGG_KNN_ANNC	94,61	99,13	98,15	97,27	95,9	96,64
BAGG_KNN_L2RLR	77,66	94,56	90,86	90,82	87,98	89,51
BAGG_KNN_BAGG	92,76	99,89	98,32	97,96	94,64	96,45
KNN_KNN_KNN	98,06	9668	95,16	98,66	97,34	97,43

Al contrario cuando se usa otro clasificador como cl2 en lugar de usar KNN, los resultados obtenidos son menores que los anteriores.

TABLA 27. RESULTADOS DE TIEMPO DE EJECUCIÓN MEDIO PARA CADA VENTANA DE TIEMPO, OBTENIDOS POR EL ALGORITMO DE COMBINACION MJ, USANDO SC.

Combinación de los algoritmos cl1 cl2 cl3	Tiempo de ejecución (s)	
	Min	Max
ANNC_KNN_ANNC	0,0486	0,0487
ANNC_KNN_L2RLR	0,0487	0,0492
ANNC_KNN_BAGG	0,0491	0,0499
BAGG_KNN_ANNC	0,0496	0,0500
BAGG_KNN_L2RLR	0,0498	0,0503
BAGG_KNN_BAGG	0,0499	0,0504
KNN	0,0505	

*Este capítulo muestra algunas comparaciones entre los resultados obtenidos anteriormente mediante clasificadores individuales y combinados, que describen el comportamiento del proceso propuesto durante todo el trabajo de investigación, que incluye pruebas usando técnicas de RTF, IRTF, IRTF reducida y SC, así como comparativas con otras técnicas propuestas en la bibliografía.*

## Capítulo 6. Comparación entre las diferentes estrategias

En esta parte se presenta un estudio comparativo entre diferentes clasificadores utilizados en la minería de datos. Durante el proceso se ha intentado, además de alcanzar un algoritmo fiable con una discriminación alta de TV y FV, emplear la menor carga computacional posible, con el fin de obtener un sistema de diagnóstico automático en tiempo real para lo cual es necesario determinar el tiempo de cálculo del algoritmo de detección.

De acuerdo a los tiempos obtenidos, resulta posible tasar el tipo de plataforma más adecuada para su implementación, la cual puede ser micro computadores, micro procesadores, FPGA, DSP, etc.

Se han realizado múltiples pruebas con distintos métodos de clasificación y distintas formas de representación de los datos RTF, IRTF y SC, en los cuales los resultados obtenidos han sido muy diversos.

A causa de la gran cantidad de métodos propuestos, las comparaciones de los resultados obtenidos es mejor separarlas por fases, como se hará a continuación.

- **Primera fase:** comparación de los resultados obtenidos por medio del clasificador KNN empleando las estrategias: AC y MRV mediante el uso de los datos RTF (ver capítulo 4). Además, se compara entre el uso de los datos RTF e IRTF no reducido empleando MRV.
- **Segunda fase:** se realiza a través de la reducción de dimensionalidad de los datos IRTF empleando las técnicas de IRTF de tamaño reducido MIP y SC, y se los compara con los resultados de IRTF no reducida.
- **Tercera fase:** se emplea la combinación de los métodos propuestos para determinar cuál es la técnica más efectiva. Se verifica su comportamiento frente a los cinco

clasificadores individuales que hemos usado, empleando los datos IRTF, IRTF reducida y SC.

- **Cuarta fase de comparación:** se presentan los mejores resultados obtenidos y se los compara con los resultados extraídos de la literatura.

A continuación se explica los resultados de cada fase de comparación:

**La primera fase:** la tabla 28 contiene un resumen de los resultados obtenidos de sensibilidad, especificidad global y exactitud global de las clases 'FV' y 'TV' resultantes de las técnicas AC y MRV empleando el clasificador KNN.

TABLA 28. RESULTADOS DE LA SENSIBILIDAD, ESPECIFICIDAD GLOBAL Y EXACTITUD GLOBAL DE LA DETECCIÓN DE LAS PATOLOGÍAS ('FV', 'TV') EMPLEANDO LOS DATOS OBTENIDOS MEDIANTE PWV USANDO LAS TÉCNICAS AC Y MRV.

Clases		FV			TV		
Técnica		Sens %	Esp %	Exa%	Sens %	Esp %	Exa %
AC	Sin filtro	74,40	94,84	90,89	70,92	98	96,64
	Con filtro	88,26	97,44	95,73	75,71	99,10	97,35
MRV	RTF, IIR	94,97	99,27	98,47	93,47	99,39	98,97
	IRTF, IIR	95,41	99,25	98,53	92,92	99,44	98,98

Comparando los resultados ofrecidos mediante el clasificador KNN se aprecia que existe una importante variación en los resultados de sensibilidad y especificidad global de 'FV' y 'TV' dependiendo de las estrategias empleadas. Esta fase se explica en dos instancias:

Para la técnica AC, como muestra la tabla 28, sin usar el filtro de la línea base se observa que el clasificador presenta porcentajes bajos de clasificación, además, se visualiza cierta variabilidad en cuanto a estos porcentajes para los valores de la sensibilidad, especificidad global de 'FV' y 'TV', con valores de una sensibilidad del 74,40%; 70,92% y una especificidad del 94,84%; 98% respectivamente.

Al utilizar el filtro de la línea base de IIR, se observa que los resultados tanto de la sensibilidad como la especificidad global y exactitud global, son superiores a los obtenidos de la clasificación sin utilizar el filtro de la línea base, sin embargo el valor de sensibilidad para TV es del 75,71%.

Se concluye que la discriminación entre las clases no es efectiva, lo que muestra una inestabilidad en el método de clasificación causada principalmente por la gran similitud entre las señales ‘TV’ y ‘FV’, siendo muy complicado realizar una mejor discriminación de las clases y mejorar el desempeño de los algoritmos. Por consiguiente, no permite alcanzar los resultados esperados utilizando la estrategia de AC. Debido que las ventanas  $V_t$  obtenidas mediante AC no tienen patrones parecidos.

En la tabla 28, se muestra que los resultados obtenidos a través de la estrategia MRV son superiores en porcentajes de sensibilidad y especificidad global, con respecto a los obtenidos por los clasificadores usándose AC. Se ha podido concluir que la estrategia de MRV utilizada ha sido un factor determinante para obtener resultados satisfactorios, lo que indica que esta metodología combinada con RTF mejora los resultados de la clasificación pudiendo resultar más efectiva en la detección de patologías. Además los valores obtenidos mediante MRV usando los datos RTF e IRTF son muy similares, debidos a que IRTF guarda la misma información que RTF transformando cada valor de energía a un pixel de intensidad entre 0 y 255.

**La segunda fase**, se realizó la comparación entre las técnicas de la reducción del tamaño de los datos IRTF MIP y SC (NC=50) empleando el clasificador KNN como se observa en la tabla 29.

En primer lugar se comparan los valores de sensibilidad y especificidad de los resultados logrados para la técnica reduciendo el tamaño de los datos IRTF mediante MIP. Los resultados obtenidos de la sensibilidad de FV y TV son ligeramente inferiores en aproximadamente un 4% en comparación con los obtenidos mediante IRTF no reducida.

En segundo lugar, al aplicar la técnica de reducción de datos por medio de SC de tamaños NC=50. Se observa que la discriminación entre FV y TV, alcanza una sensibilidad del 88,58%, una especificidad global del 98,74% y una exactitud global del 96,82% para FV y un sensibilidad del 90,09%, una especificidad global del 99,06% y exactitud global del 98,41% para TV, con un tiempo de ejecución de  $t = 0,0505s$ . Se debe tener en cuenta que al emplear SC, únicamente se seleccionan aquellas características que pueden hacer un aporte importante para mejorar la tasa de rendimiento de clasificación, descartando aquellas características que no tienen buena capacidad discriminante, lo cual no es frecuente debido al ruido existente y al tamaño de los datos seleccionados pudiendo perder más información. Como se ha comentado

anteriormente, al aumentar el tamaño de SC se mejora el comportamiento pero se aumenta el tiempo de ejecución.

TABLA 29. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD GLOBAL Y EXACTITUD GLOBAL DE LA DETECCIÓN DE LAS PATOLOGÍAS('FV', 'TV') Y EL TIEMPO DE EJECUCIÓN MEDIO PARA CADA VENTANA DE TIEMPO EMPLEANDO LOS DATOS OBTENIDOS MEDIANTE PWV USANDO LAS TÉCNICAS REDUCCIÓN DE LOS DATOS MIP Y SC(NC=50).

Clases		FV%			TV%			Tiempo de ejecución (s)
Datos		Sens %	Esp %	Exa %	Sens%	Esp %	Exa%	
IRTF no reducida		95,41	99,25	98,53	92,92	99,44	98,98	0,1682
IRTF reducida	MIP 3x5	88,27	98,22	96,35	88,31	98,80	98,05	0,0246
SC	NC=50	88,58	98,74	96,82	90,09	99,06	98,41	0,0505

También se observa que no existen diferencias estadísticamente significativas entre los resultados obtenidos por los dos métodos de reducción de dimensionalidad. Sin embargo el tiempo de ejecución es mayor en el caso de SC en comparación con MIP debido a que el tamaño de los datos usando MIP es 3x5 (15) mientras que el de SC es de 50 características.

De manera general, se concluye que los resultados conseguidos a través de las dos técnicas de dimensionalidad reducida (IRTF reducida y SC) son ligeramente menores a los resultados que se obtienen mediante el uso de la RTF e IRTF no reducida. Esto es debido a que en las técnicas de dimensionalidad reducida no se aplican todos los datos de entrada que se aplican en las técnicas no reducidas. Esto se traduce en una pérdida de información. Por otro lado, el conjunto de datos de IRTF no reducida es más grande y contiene más información asociada, pero el proceso computacional se hace más lento y exigente, la reducción en el volumen de datos que se utiliza en las técnicas con dimensionalidad reducida permite disminuir el tiempo de ejecución hasta diez veces con respecto las técnicas no reducidas. Esto se traduce en un menor coste computacional, y aumenta de la velocidad de procesamiento.

Se puede concluir que pese a que las dos técnicas de dimensionalidad reducidas muestran similares resultados de sensibilidad y especificidad, la técnica de IRTF reducida MIP es la mejor opción debido a que su tiempo de ejecución es más rápido que el observado en SC.

**En la tercera fase de comparación,** se realizó una comparación entre los resultados obtenidos mediante el método de combinación de MJ usando los datos IRTF, IRTF reducida y SC.

TABLA 30. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD GLOBAL Y EXACTITUD GLOBAL DE LA DETECCIÓN DE LAS PATOLOGÍAS ('FV', 'TV') Y TIEMPO DE EJECUCIÓN MEDIO PARA CADA VENTANA DE TIEMPO MEDIANTE LA COMBINACIÓN DE LOS ALGORITMOS MJ EMPLEANDO LOS DATOS OBTENIDOS MEDIANTE IRTF, IRTF REDUCIDA (MIP), SC (NC=50).

		FV			TV		
Datos	Algoritmos de combinación	Sens%	Esp %	Exa %	Sens%	Esp %	Exa %
<b>IRTF no reducida</b>	ANNC_KNN_ANNC	95,13	99,1	98,41	92,32	99,33	98,9
<b>MIP</b>	ANNC_KNN_ANNC	92,14	98,07	97,07	89,02	80,78	98,08
<b>SC(NC=50)</b>	ANNC_KNN_ANNC	92,6	98,68	97,52	89,3	99,01	98,32

TABLA 31. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD GLOBAL Y EXACTITUD GLOBAL DE LA DETECCIÓN DE LAS PATOLOGÍAS ('OTROS', 'NORMAL') MEDIANTE LA COMBINACIÓN DE LOS ALGORITMOS MJ EMPLEANDO LOS DATOS OBTENIDOS MEDIANTE IRTF, IRTF REDUCIDA (MIP), SC (NC=50).

		Otros			Normal		
Datos	Algoritmos de combinación	Sens%	Esp %	Exa %	Sens%	Esp %	Exa %
<b>IRTF no reducida</b>	ANNC_KNN_ANNC	97,22	99,57	99,06	99,04	98,1	98,61
<b>MIP</b>	ANNC_KNN_ANNC	95,59	99,5	98,65	98,31	97,46	97,92
<b>SC(NC=50)</b>	ANNC_KNN_ANNC	94,52	99,25	98,22	98,28	96,27	97,36

En las tablas 30, 31 y 32 se aprecia que, para el conjunto IRTF no reducido, cuando se usa el método MC se obtiene una sensibilidad del 95,13%, especificidad del 99,1% para FV, una sensibilidad del 92,32%, especificidad del 99,33% para TV y tiempo de ejecución entre [0,0491s; 0,1016s] , y en el caso usando los datos IRTF reducida utilizando MIP y SC se obtiene una sensibilidad del 92,14%; 92,6%, especificidad del 98,07%; 98,68% para FV, una sensibilidad 89,02%; 89,3%, especificidad 80,78%; 99,01% para TV y tiempo de ejecución entre [0,0239; 0,0241s], [0,0487s; 0,0492s] respectivamente.

Al emplear MJ usando los datos ITRF no reducida, ITRF reducida MIP y SC se obtienen unos valores altos de sensibilidad y especificidad, y además un tiempo de ejecución reducido al compararlos con los obtenidos por el clasificador KNN individual.

Con todos los resultados obtenidos se puede recomendar el uso las combinaciones de los algoritmos como mejor método de clasificación. Además, los resultados obtenidos mediante el

método multclasificador (ANNC\_KNN\_ANNC) usando MJ son mejores en la detección comparados con los obtenidos mediante los algoritmos utilizados individualmente y otros multclasificadores aplicando los datos de IRTF reducidas, debido que el clasificador ANNC se usa en MJ como clasificadores (cl1, cl3) y KNN se usa como cl2 (ver la figura 48); por un lado el clasificador ANNC tiene un buen comportamiento en la discriminación entre las clases ‘Normal’ y ‘Otros’, también entre las clases ‘NormalOtros’ y ‘FVTV’, con un tiempo de ejecución rápido en comparación con el algoritmo KNN. Además KNN tiene un buen comportamiento en la separación entre ‘FV’ y ‘TV’.

TABLA 32. RESULTADOS DE TIEMPO DE EJECUCIÓN MEDIO PARA CADA VENTANA DE TIEMPO MEDIANTE LA COMBINACIÓN DE LOS ALGORITMOS MJ EMPLEANDO LOS DATOS OBTENIDOS MEDIANTE IRTF, IRTF REDUCIDA (MIP), SC(NC=50).

Datos	Algoritmos de combinación	Tiempo d ejecución (s)	
		Min	Max
IRTF no reducida	ANNC_KNN_ANNC	0,0491	0,1016
MIP	ANNC_KNN_ANNC	0,0239	0,0241
SC(NC50)	ANNC_KNN_ANNC	0,0487	0,0492

## Comparación con otros métodos

En las Tablas 33 y 34 se presenta una comparación del algoritmo propuesto en cuanto a sensibilidad, especificidad global, y exactitud global con diferentes métodos. Estos métodos son frecuentemente citados en la literatura, para comprobar en qué medida los datos obtenidos apoyan nuestra hipótesis. En estas tablas aparecen los resultados del clasificador KNN individual y los del método multclasificador ANNC\_KNN\_ANNC obtenidos mediante los datos de IRTF no reducidas, IRTF reducida MIP y SC.

TABLA 33. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD GLOBAL Y EXACTITUD GLOBAL DE LA DETECCIÓN DE LAS PATOLOGÍAS ('FV', 'TV') OBTENIDOS PARA LA CLASIFICACIÓN DE LAS ARRITMIAS CARDIACAS POR EL MÉTODO PROPUESTO EN ESTE TRABAJO Y OTROS MÉTODOS.

Tipos	FV			TV			Base de datos
	Sens%	Esp%	Exa%	Sens%	Esp%	Exa%	
Métodos							
<b>Este trabajo, KNN, RTF: 45 × 150</b>	94,97	99,27	98,47	93,47	99,39	98,97	AHA & MIT-DB
<b>Este trabajo, KNN, IRTF: 45 × 150</b>	95,41	99,25	98,53	92,92	99,44	98,98	AHA & MIT-DB
<b>Este trabajo, KNN, IRTF: 3 × 5 (MIP)</b>	88,27	98,22	96,35	88,31	98,80	98,05	AHA & MIT-DB
<b>Este trabajo, KNN, SC(N=50)</b>	88,58	98,74	96,82	90,09	99,06	98,41	AHA & MIT-DB
<b>Este trabajo, ANN_KNN_ANNC, IRTF: 45 × 150</b>	95,13	99,1	98,41	92,32	99,33	98,9	AHA & MIT-DB
<b>Este trabajo, ANN_KNN_ANNC, IRTF: 3 × 5 (MIP)</b>	92,14	98,07	97,07	89,02	80,78	98,08	AHA & MIT-DB
<b>Este trabajo, ANN_KNN_ANNC, SC(N=50)</b>	92,6	98,68	97,52	89,3	99,01	98,32	AHA & MIT-DB
[144], usando Boltzmann	92,52			76,01			MIT-DB
[145], usando Discriminant Analysis	94,10	93,80					AHA & MIT-DB
[146], usando Filter and Counts	94,40	95,90	94,7				AHA & MIT-DB
[147], usando SVM	96,20	96,20	96,3				AHA & MIT-DB
[148], usando Lempel-Ziv and EMD	98,15	96,01	97,1				CU & MIT-DB
[149], usando Type 2 fuzzy			90,9			84,0	MIT-DB
[149], usando Neural SOM			100,0			48,0	MIT-DB
[150], usando Type 2 TSK Fuzzy			93,3			92,0	MIT-DB
[150], usando Type 2 Mamdani Fuzzy			86,6			88,0	MIT-DB
[151], usando Fuzzy Simil App Entropy	97,98	97,03	97,5				CU & MIT-DB
[151], usando Approximate Entropy	91,84	90,2	91,0				MIT-DB
[152], usando EMD & App Entropy	90,47	91,66	91,2				MIT-DB
[153], usando KNN	98,10	88,00	93,2				MIT-DB
[153], usando RBF	91,53	90,91	91,3				MIT-DB

TABLA 34. RESULTADOS DE SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD DE LA DETECCIÓN DE LAS PATOLOGÍAS ('OTROS', 'NORMAL') OBTENIDOS PARA LA CLASIFICACIÓN DE LAS ARRITMIAS CARDIACAS POR EL MÉTODO PROPUESTO EN ESTE TRABAJO Y OTROS MÉTODOS.

Tipos	Otros			Normal			Base de datos
	Métodos	Sen%	Esp%	Exa%	Sen%	Esp%	
Este trabajo, KNN, RTF: 45 × 150	97,69	99,40	99,03	99,07	98,29	98,71	AHA & MIT-DB
Este trabajo, KNN, IRTF: 45 × 150	97,71	99,50	99,11	99,20	98,34	98,80	AHA & MIT-DB
Este trabajo, KNN, IRTF: 3 × 5 (MIP)	96,91	99,06	98,59	98,14	96,82	97,53	AHA & MIT-DB
Este trabajo, KNN, SC(N50)	97,05	98,52	98,20	98,06	96,68	97,43	AHA & MIT-DB
Este trabajo, ANN_KNN_ANNC, IRTF: 45 × 150	97,22	99,57	99,06	99,04	98,1	98,61	AHA & MIT-DB
Este trabajo, ANN_KNN_ANNC, IRTF: 3 × 5 (MIP)	95,59	99,5	98,65	98,31	97,46	97,92	AHA & MIT-DB
Este trabajo, ANN_KNN_ANNC, SC(N50)	94,52	99,25	98,22	98,28	96,27	97,36	AHA & MIT-DB
[144], usando Boltzmann	81,04						MIT-DB
[145], usando Discriminant Analysis							AHA & MIT-DB
[146], usando Filter and Counts							AHA & MIT-DB
[147], usando SVM							AHA & MIT-DB
[148], usando Lempel-Ziv and EMD							CU & MIT-DB
[149], usando Type 2 fuzzy						100,0	MIT-DB
[149], usando Neural SOM						88,0	MIT-DB
[150], usando Type 2 TSK Fuzzy						100,0	MIT-DB
[150], usando Type 2 Mamdani Fuzzy						100,0	MIT-DB
[151], usando Fuzzy Simil App Entropy							CU & MIT-DB
[151], usando Approximate Entropy							MIT-DB
[152], usando EMD & App Entropy							MIT-DB
[153], usando KNN							MIT-DB
[153], usando RBF							MIT-DB

En [151] Xie et al utilizan la entropía aproximada para distinguir entre ‘FV’ y ‘TV’ con buenas tasas de rendimiento de FV (Sens = 91,84%; Esp = 90,2%; Exa = 91 %) empleando la misma base de datos de señal. Además, también proponen una versión modificada utilizando entropía difusa aproximada basada en la similitud que a su vez ha conseguido un alto rendimiento de ‘FV’ (Sens = 97,98%; Esp = 97,03%; Exa = 97,5 %).

Aunque se obtuvieron los valores más altos, para hacer una comparación equitativa entre ambos análisis, se tiene que tener en cuenta que el análisis realizado utiliza una representación con episodios limpios de ‘VT’ y ‘VF’ como datos de entrada, mientras que en nuestro trabajo se usa una clasificación de multiclases: cuatro clases (‘FV’, ‘TV’, ‘Otros’, ‘Normal’).

Lo mismo ocurre para otros estudios que distinguen entre ritmos ‘FV’ y ‘TV’. Por lo tanto, más tarde Kaur y Singh [152] utilizan entropía aproximada pero con descomposición empírica de modo (EMD) y un conjunto de datos de Xie más reducido, que tiene buenos valores de rendimiento de ‘FV’ (Sens = 90,47%; Esp = 91,66%; Exa = 91,2 %).

Más tarde, Xia et Alabama [148] usan un número representativo de episodios limpios de cada patología, y ellos también tuvieron un alto rendimiento de ‘FV’ (Sens = 98,15%; Esp = 96,01%; Exa = 97,1 %).

Lo mismo ocurrió a Li et al [147] utilizando SVM, que también obtuvieron buenos valores de rendimiento de ‘FV’ (Sens = 96,2%; Esp = 96,2%; y Exa = 96,3 %) para una ventana de 2s. Otros trabajos ofrecen buenas tasas de rendimiento que distinguen entre FV y TV [153].

Siguiendo esta línea, nos encontramos con otros trabajos comparables al nuestro con el objetivo de distinguir también entre el ritmo sinusal normal (Normal), aparte de la ‘TV’ o la ‘FV’. Dentro de estos trabajos, Tan et al.[149] obtuvieron buenos resultados de exactitud (Exa (‘FV’) = 90,9%; Exa (‘TV’) = 84, 0%; Exa (‘Normal’) = 100 %) usando un clasificador tipo-2 basado en la lógica difusa para una clasificación de tres clases (‘FV’, ‘TV’ y ‘Normal’). También describieron los resultados de la utilización de una red neuronal SOM, obtenida pero con malos valores de exactitud de ‘TV’. Más tarde, Phong et Alabama [150] siguieron la misma línea de la aplicación de otra multi-clase utilizando el clasificador (sistema difuso tipo-2 TSK), con mejores valores de exactitud (ExaFV = 93,3%; ExaTV = 92,0%; ExaN = 100 %).

En este trabajo de investigación se ha comprobado que en todas las estrategias usadas se refleja un comportamiento muy similar. De este modo, los resultados producidos son comparables con

los que han sido obtenidos por otros investigadores que han trabajado en el mismo campo. En cambio, Hay que resaltar que la mayoría de trabajos en la bibliografía solo utilizan entre dos o tres clases en la detección de 'FV', mientras en nuestro trabajo se utilizan cuatro clases lo que dificulta el proceso de clasificación. No existen reportes sobre el tiempo de ejecución de los clasificadores empleados por otros autores; en este caso, la IRTF de tamaño reducido usando MIP y SC usando el método de multclasificador proporciona unos resultados de clasificación elevados con un tiempo de cálculo muy bajo (del orden de 20 ms en el PC empleado).

*En este capítulo se describen brevemente las conclusiones a las que se ha llegado en esta investigación y mostramos las futuras direcciones.*

## Capítulo 7. Conclusiones

Como se ha mencionado anteriormente, una de las principales causas de muerte súbita está provocada por la arritmia de FV. Muchas de las víctimas de paro cardíaco súbito pueden sobrevivir si los testigos actúan de forma inmediata después de la aparición de los primeros síntomas.

La evidencia científica indica que la aplicación temprana de desfibrilación mediante un choque eléctrico de alta energía sobre el pecho del paciente para facilitar el reinicio de la actividad eléctrica cardíaca normal es determinante para la recuperación de la víctima, siendo este el único tratamiento definitivo posible para la FV.

El diagnóstico erróneo de la TV como FV en un paciente puede ocasionarle graves lesiones ya que la aplicación de una terapia contra la FV (desfibrilación) a un paciente que sufre TV puede causarle una fibrilación ventricular.

La detección rápida y correcta de la FV y la TV es de fundamental importancia tanto para la utilización de un desfibrilador externo automático como para la monitorización del paciente, además de obtener un algoritmo fiable, se ha intentado realizar esta tarea de detección empleando la menor carga computacional posible.

En la metodología se emplea el ECG para monitorizar las señales biomédica que tienen diferentes características morfológicas y espectrales. Además, pueden tener ruidos causados por las patologías que se analizan, y la presencia de ruido provocado por varios factores externos al corazón tales como los movimientos del paciente, la línea base, la respiración, interferencias, etc. En primer lugar, se inició con la descripción del sistema cardiovascular y una introducción de la anatomía del corazón humano, así como de su sistema de conducción eléctrica. También las características de la señal del ECG normal, las formas de sus ondas, sus intervalos, y las bases teóricas del sistema de derivaciones. Luego, una vez conocido el

problema y las herramientas a emplear, se procede al análisis de las señales mediante la extracción de la información en la RTF y la IRTF.

Inicialmente se describen las bases de datos de señales electrocardiográficas utilizadas, agrupando las señales en cuatro clases: Ritmo sinusal normal ('Normal'), Taquicardia Ventricular ('TV'), Fibrilación Ventricular ('FV') incluido el Flutter Ventricular y 'Otros'.

Luego, se presenta una revisión bibliográfica de los métodos y técnicas de detección FV que existen en la actualidad, así como sus aplicaciones a las señales ECG para su pre-procesamiento.

Seguido de la descripción de las técnicas de filtrado, la reducción de las perturbaciones de la línea base y el algoritmo desarrollado para la detección de las marcas de referencia correspondientes a las ventanas de tiempo, a partir de las que se calcula la RTF.

También se describen las limitaciones en el análisis de señales no estacionarias, y las expresiones matemáticas correspondientes a las principales distribuciones de tiempo-frecuencia.

Se realiza una introducción, descripción y fundamentos matemáticos de las distribuciones tiempo-frecuencia lineales y cuadráticas.

Se propone el análisis de la señal ECG para la detección en tiempo real de la aparición de la fibrilación ventricular mediante un método tiempo-frecuencia. Se llevó a cabo una reducción de la interferencia de la red y otros ruidos, que corresponden a ruidos de alta frecuencia en estas señales.

Una vez realizado los pasos anteriores, se convierte la matriz de datos de cada RTF a una imagen IRTF correspondientes a las diferentes patologías cardiacas de la señal ECG procesada, que permitan obtener una representación apropiada capaz de proporcionar información útil acerca del problema a resolver, y su posible aplicación práctica hacia el diagnóstico en tiempo real.

Posteriormente se han analizado las posibilidades existentes de reducción de dimensionalidad ante su implementación real como sistema de monitorización eliminando los parámetros incapaces de realizar una separación entre clases, obteniendo así un conjunto reducido de características.

Además se realizó una descripción bibliográfica de los principales modelos de aprendizaje empleados en este trabajo de investigación.

Se realizó un análisis de las principales metodologías, como un estudio comparativo entre el desempeño individual de los algoritmos KNN, ANNC, L2\_RLR, SSVM y BAGG, y se empleó la combinación de los mismos.

Por último se ha realizado una comparación entre los resultados obtenidos en esta investigación y trabajos similares conocidos en la literatura.

Todos estos algoritmos de clasificadores, individuales y combinados, fueron entrenados con el método de validación cruzada y evaluados basándose en la sensibilidad, especificidad, exactitud y tiempos de ejecución.

Lo novedoso ha sido, por un lado usar la estrategia de MRV para ventanas de análisis  $V_t$ , y por otro lado, las matrices RTF, IRTF usadas como entrada al algoritmo de clasificación sin necesidad de obtener parámetros para el clasificador, lo que nos permite descartar la etapa típica de extracción de características evitando la pérdida de información relevante para discriminar entre las diferentes clases, pudiendo ofrecer mejores resultados en la detección de las arritmias ventriculares.

La clasificación realizada en la discriminación de FV y TV nos mostró cómo se comportan los distintos algoritmos de clasificación tanto individuales como combinados al aplicarse sobre un mismo conjunto de datos.

Usando la estrategia IRTF no reducida, tenemos que el clasificador KNN alcanza resultados buenos en la fase de entrenamiento como en la de prueba logrando una sensibilidad del 94,97 %, especificidad del 99,27 % para FV, y una sensibilidad del 93,47 y especificidad del 99,39 % para TV. Además, tenemos el clasificador ANNC que ha logrado una sensibilidad del 95,56% y especificidad del 98,80 % para FV, una sensibilidad del 88,80% y especificidad del 99,52% para TV que lo ubica en segundo lugar.

No obstante, al realizar las combinaciones entre ellos, notamos que el tiempo de ejecución mejora.

Usando la estrategia IRTF reducida, el tiempo de ejecución disminuye, y al utilizarlos combinados disminuye aún más, dando resultados buenos en diagnóstico.

Tomando en consideración lo realizado, tenemos que el uso de combinaciones y reducciones son la mejor manera de integrar la información de diversas fuentes, ya que proporcionan estimaciones más fuertes y eficientes que cuando se emplea un único clasificador.

Después de un largo análisis es posible concluir que la metodología propuesta brinda información útil para la detección de FV en tiempo real con un bajo tiempo de cómputo, discriminándola satisfactoriamente del resto de patologías cardíacas, mejorando significativamente las posibilidades de diagnóstico correcto del paciente al presentar un episodio con alguna de estas arritmias.

Como trabajo futuro, se puede plantear la aplicación de otras técnicas de reducción de dimensionalidad y comparar los resultados con los obtenidos en este trabajo. Además, probar otros clasificadores, crear otras combinaciones, ajustar parámetros e intentar mejorar los resultados obtenidos.

## Bibliografía

- [1] J. Malmivuo and R. Plonsey, “Bioelectromagnetism: principles and applications of bioelectric and biomagnetic fields,” *Oxford Univ. Press. USA*, 1995.
- [2] C.-H. Cappelaere, “Estimation du risque de mort subite par arrêt cardiaque à l’aide de méthodes d’apprentissage artificiel,” Paris 6, 2014.
- [3] M. S. Thaler, “The Only EKG Book You’ll Ever Need,” Lippincott Williams and Wilkins, 2010.
- [4] J. Ibáñez and J. Roig, “Estimación de la actividad auricular en episodios de fibrilación auricular mediante separación ciega de fuentes,” Universidad Politécnica de Valencia, 2003.
- [5] J. Torrecilla, “Implementación y estudio de métodos numéricos para la resolución del problema directo e inverso de la electrocardiografía: modelado de la actividad eléctrica en la,” 2011.
- [6] J. Sotos, “Aplicación de redes neuronales artificiales en el procesado versátil de señales electrocardiográficas,” 2012.
- [7] R. Navarro and G. Perdomo, “Propedeutica clinica y semiologia medica tomo I,” *Editor. Ecimed, Barcelona*, 2013.
- [8] M. Sanmartín, D. Cuevas, J. Goicolea, R. Ruiz-Salmerón, M. Gómez, and V. Argibay, “Complicaciones vasculares asociadas al acceso transradial para el cateterismo cardíaco,” *Rev Esp Cardiol*, vol. 57, no. 6, pp. 581–584, 2004.
- [9] R. Leta, F. Carreras, X. Alomar, J. Monell, J. García-Picart, J. M. Augé, A. Salvador, and Pons-Lladó, “Coronariografía no invasiva mediante tomografía computarizada con 16 detectores: estudio comparativo con la angiografía coronaria invasiva,” *Rev. Española Cardiol.*, vol. 57, no. 3, pp. 217–24, 2004.
- [10] A. D. Waller, “A demonstration of man of electromotive changes accompanying the heart’s beat,” *Annals of Noninvasive Electrocardiology*, vol. 9, no. 2. pp. 189–191, 2004.
- [11] S. Galveño and R. Gallero, “CA 2-101: Papel del holter en el diagnóstico de la

- enfermedad del seno: A propósito de un caso,” *Enfermería*, 2016.
- [12] J. de Agustín and P. Marcos-Alberca, “Puente miocárdico evaluado mediante tomografía computarizada multidetectores: posible causa del dolor torácico en pacientes más jóvenes con baja prevalencia de,” *Rev. Española*, 2012.
- [13] K. Swedberg, J. Cleland, and H. Dargie, “Guías de Práctica Clínica sobre el diagnóstico y tratamiento de la insuficiencia cardíaca crónica. Versión resumida (actualización 2005),” *Rev. Española*, 2005.
- [14] J. Sanz, L. Fernández-Friera, and S. Moral, “Técnicas de imagen en la evaluación del corazón derecho y la circulación pulmonar,” *Rev. española Cardiol.*, 2010.
- [15] M. elena Irazola, Vilma and Fernandez, Roberto and Poyatos, “Comparacion entre la ergometria y la prueba electrocardiografica con dobutamina para predecir lesiones angiograficas en pacientes con infarto agudo de miocardio no complicado,” *CARDIOL*, vol. 70, pp. 168–176, 2002.
- [16] A. Peralta, “Papel de la prueba de adenosina en el síncope de origen desconocido,” *Rev. Argent. Cardiol.*, 2011.
- [17] C. Niño, J. Perez, and M. Quimbayo, “Implementación de un modelo para la representación vectorial de la actividad eléctrica del corazón en un espacio tridimensional,” *Sci.*, vol. 21, no. 1, pp. 75–85, 2016.
- [18] J. D. Echeverry, A. F. López, and J. F. López, “Reconocimiento de valvulopatías cardíacas en señales de fonocardiografía empleando la transformada gabor,” *Sci. Tech. Año XIII*, no. 34, pp. 139–143, 2007.
- [19] F. Gascó, “Ecocardiografía-doppler,” 2011.
- [20] G. D. Clifford, F. Azuaje, and P. E. McSharry, *Advanced Methods and Tools for ECG Data Analysis*. Artech House, Inc., 2006.
- [21] W. Einthoven, “The Different Forms of the Human Electrocardiogram and their Signification,” *Lancet*, vol. 179, no. 4622, pp. 853–861, 1912.
- [22] R. Oter Rodríguez, J. de Juan Montiel, T. Roldán Pascual, A. Bardají Ruiz, and E. Molinero de Miguel, “Guías de práctica clínica de la Sociedad Española de Cardiología

- en marcapasos,” *Rev. Esp. Cardiol.*, vol. 53, no. 7, pp. 947–966, 2000.
- [23] J. E. Erichsen, “On the influence of the coronary circulation on the action of the heart,” *London Med. Gaz.*, vol. 2, pp. 561–564, 1842.
- [24] W. E. Garrey, “The nature of fibrillary contraction of the heart. Its relation to tissue mass and form.,” *Am J Physiol*, vol. 33, no. 3, pp. 397–414, 1914.
- [25] S. de Boer, “Die Physiologie und Pharmakologie des Flimmerns,” *Ergebnisse der Physiol.*, vol. 21, no. 1, pp. 1–165, 1923.
- [26] E. Asensio, R. Narváez, J. Dorantes, J. Oseguera, A. O. T, P. H. R, and V. R. G, “Conceptos actuales sobre la muerte súbita,” *Gac. Med. Mex.*, vol. 141, no. 2, pp. 89–98, 2005.
- [27] U. K. Amann. Anton, Tratnig.Robert, “Reliability of old and new ventricular fibrillation detection algorithms for automated external defibrillators.,” *Biomed. Eng. Online*, vol. 4, no. 1, p. 60, 2005.
- [28] P. Cardiac and A. P. Defibrillation, “Paro cardiorrespiratorio prehospitario . Desfibrilación de acceso público,” *Rev. argentina*, vol. 80, no. 2, pp. 160–164, 2012.
- [29] C. Abecia-inchaurregui, “Factores asociados a la mortalidad extrahospitalaria de las paradas ´sico cardiorrespiratorias atendidas por unidades de soporte vital ba ´s Vasco en el Pai,” *Esp Cardiol.*, vol. 66, no. 4, pp. 269–274, 2013.
- [30] A. Bhatia, R. Cooley, M. Berger, Z. Blanck, A. Dhala, J. Sra, K. Axtell-McBride, C. VanderVort, and M. Akhtar, “The implantable cardioverter defibrillator: Technology, indications, and impact on cardiovascular survival,” *Current Problems in Cardiology*, vol. 29, no. 6. pp. 303–356, 2004.
- [31] J. Jeong and W. Williams, “Kernel design for reduced interference distributions,” *IEEE Trans. Signal Process.*, vol. 40, no. 2, pp. 402–412, 1992.
- [32] M. A. Othman, N. M. Safri, I. A. Ghani, F. K. C. Harun, and I. Ariffin, “A new semantic mining approach for detecting ventricular tachycardia and ventricular fibrillation,” *Biomed. Signal Process. Control*, vol. 8, no. 2, pp. 222–227, 2013.
- [33] L. Sörnmo and P. Laguna, *Bioelectrical signal processing in cardiac and neurological*

- applications*. Academic Press, 2005.
- [34] A. Carmona, “Application of Hilbert-Huang Transform To Detect Hydroclimatic Variability Modes in Colombia P [,” *DYNA*, vol. 79, no. 175, pp. 72–80, 2012.
- [35] M. Grewal and A. Andrews, “Kalman theory, theory and practice using MATLAB,” 2008.
- [36] G. F. Hlawatsch, Franz and Boudreaux-Bartels, “Linear and quadratic time-frequency signal representations,” *IEEE Signal Process. Mag.*, vol. 9, no. 2, pp. 21–67, 1992.
- [37] A. L. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C.-K. Peng, and H. E. Stanley, “PhysioBank, PhysioToolkit, and PhysioNet : Components of a New Research Resource for Complex Physiologic Signals,” *Circulation*, vol. 101, no. 23, pp. e215–e220, Jun. 2000.
- [38] M. Ahlstrom and W. Tompkins, “Digital filters for real-time ECG signal processing using microprocessors,” *IEEE Trans. Biomed. Eng.*, no. 9, pp. 708–713, 1985.
- [39] J. Łęski and N. Henzel, “ECG baseline wander and powerline interference reduction using nonlinear filter bank,” *Signal Processing*, vol. 85, no. 4, pp. 781–793, 2005.
- [40] S. Luo and P. Johnston, “A review of electrocardiogram filtering,” *J. Electrocardiol.*, vol. 43, no. 6, pp. 486–496, 2010.
- [41] R. Rangayyan and N. Reddy, “Biomedical signal analysis: a case-study approach,” *Ann. Biomed. Eng.*, vol. 30, no. 7, pp. 983–983, 2002.
- [42] L. Sörnmo, “Time-varying digital filtering of ECG baseline wander,” *Med. Biol. Eng. Comput.*, vol. 31, no. 5, pp. 503–503, 1993.
- [43] X. Liu, Y. Zheng, and M. Phyu, “Multiple functional ECG signal is processing for wearable applications of long-term cardiac monitoring,” *IEEE Trans. Biomed. Eng.*, vol. 58, no. 2, pp. 380–389, 2011.
- [44] S. Pei and C. Tseng, “Elimination of AC interference in electrocardiogram using IIR notch filter with transient suppression,” *IEEE Trans. Biomed. Eng.*, vol. 42, no. 11, pp. 1128–1132, 1995.

- [45] C. Tseng and S. Pei, "Design of an equiripple FIR notch filter using a multiple exchange algorithm," *Signal Processing*, vol. 75, no. 3, pp. 225–237, 1999.
- [46] C. Tseng and S. Pei, "Stable IIR notch filter design with optimal pole placement," *IEEE Trans. Signal Process.*, vol. 49, no. 11, pp. 2673–2681, 2001.
- [47] Y. Lin and Y. Hu, "Power-line interference detection and suppression in ECG signal processing," *IEEE Trans. Biomed. Eng.*, vol. 55, no. 1, pp. 354–357, 2008.
- [48] F. Odille and C. Pasquier, "Noise cancellation signal processing method and computer system for improved real-time electrocardiogram artifact correction during MRI data acquisition," *IEEE Trans. Biomed. Eng.*, vol. 54, no. 4, pp. 630–640, 2007.
- [49] M. Okada, "A digital filter for the QRS complex detection," *IEEE Trans. Biomed. Eng.*, vol. 26, no. 12, pp. 700–703, 1979.
- [50] D. Donoho, "De-noising by soft-thresholding," *IEEE Trans. Inf. theory*, vol. 41, pp. 613–627, 1995.
- [51] E. Ercelebi, "Electrocardiogram signals de-noising using lifting-based discrete wavelet transform," *Comput. Biol. Med.*, vol. 34, no. 6, pp. 479–493, 2004.
- [52] A. Al-Fahoum and I. Howitt, "Combined wavelet transformation and radial basis neural networks for classifying life-threatening cardiac arrhythmias," *Med. Biol. Eng. Comput.*, vol. 37, no. 5, pp. 566–573, 1999.
- [53] M. Rahman, R. Shaik, and D. Reddy, "Efficient sign based normalized adaptive filtering techniques for cancelation of artifacts in ECG signals: Application to wireless biotelemetry," *Signal Processing*, vol. 91, no. 2, pp. 225–239, 2011.
- [54] R. Diversi, R. Guidorzi, and U. Soverini, "Kalman filtering in extended noise environments," *IEEE Trans. Automat. Contr.*, vol. 50, no. 9, pp. 1396–1402, 2005.
- [55] R. Sameni and M. Shamsollahi, "A nonlinear Bayesian filtering framework for ECG denoising," *IEEE Trans. Biomed. Eng.*, vol. 54, no. 12, pp. 2172–2185, 2007.
- [56] R. Sameni, "Model-based Bayesian filtering of cardiac contaminants from biomedical recordings," *Physiol. Meas.*, vol. 29, no. 5, p. 595, 2008.

- [57] R. Vullings, “An adaptive Kalman filter for ECG signal enhancement,” *IEEE Trans. Biomed. Eng.*, vol. 5, no. 4, pp. 1094–1103, 2011.
- [58] M. Izzetoglu and A. Devaraj, “Motion artifact cancellation in NIR spectroscopy using Wiener filtering,” *IEEE Trans. Biomed. Eng.*, vol. 52, no. 5, pp. 934–938, 2005.
- [59] L. Chmelka and J. Kozumplik, “Wavelet-based wiener filter for electrocardiogram signal denoising,” *Comput. Cardiol. 2005*, pp. 771–774, 2005.
- [60] A. B. Cañizares, *Diseño, desarrollo y test de un prototipo de pulsera para adquirir el electrocardiograma y la onda de pulso*. Universitat Politècnica de Catalunya, 2016.
- [61] M. Kaur, B. Singh, and Seema, “Comparison of different approaches for removal of baseline wander from ECG signal,” in *Proceedings of the International Conference & Workshop on Emerging Trends in Technology - ICWET '11*, 2011, pp. 1290–1294.
- [62] A. Mjahad, A. Rosado-Muñoz, M. Bataller-Mompeán, J. V. Francés-Víllora, and J. F. Guerrero-Martínez, “Ventricular Fibrillation and Tachycardia detection from surface ECG using time-frequency representation images as input dataset for machine learning,” *Comput. Methods Programs Biomed.*, vol. 141, pp. 119–127, 2017.
- [63] M. Viitasalo and J. Karjalainen, “QT intervals at heart rates from 50 to 120 beats per minute during 24-hour electrocardiographic recordings in 100 healthy men. Effects of atenolol.,” *Circulation*, vol. 86, no. 5, pp. 1439–1442, 1992.
- [64] B. Boashash, “Time-frequency signal analysis and processing: a comprehensive reference,” Academic Press, 2015.
- [65] E. Wigner, “On the quantum correction for thermodynamic equilibrium,” *Phys. Rev.*, vol. 40, no. 5, p. 749, 1932.
- [66] W. Koenig, H. Dunn, and L. Lacy, “The sound spectrograph,” *J. Acoust. Soc. Am.*, vol. 18, no. 1, pp. 19–49, 1946.
- [67] L. Cohen, “Generalized phase-space distribution functions,” *J. Math. Phys.*, vol. 7, no. 5, pp. 781–786, 1966.
- [68] L. Cohen, “Time-frequency distributions-a review,” *Proc. IEEE*, vol. 77, no. 7, pp. 941–981, 1989.

- [69] L. Cohen, “Time-frequency analysis,” 1995.
- [70] J. Poynting, “On the transfer of energy in the electromagnetic field,” *Philos. Trans. R. Soc. London*, vol. 175, pp. 343–361, 1884.
- [71] L. Rayleigh, “LIII. On the character of the complete radiation at a given temperature,” *The London, Edinburgh, Dublin Philos. Mag. J. Sci.*, vol. 27, no. 169, pp. 460–469, 1889.
- [72] A. Rihaczek and E. Bedrosian, “Hilbert transforms and the complex representation of real signals,” *Proc. IEEE*, vol. 54, no. 3, pp. 434–435, 1966.
- [73] M. Al-Manie, “Deconvolution methods for biomedical signals analysis,” *Indian J. Sci. Technol.*, vol. 3, no. 2, pp. 105–109, 2010.
- [74] A. Mousa and R. Saleem, “Using reduced interference distribution to analyze abnormal cardiac signal,” *J. Electr. Eng.*, vol. 62, no. 3, pp. 168–172, 2011.
- [75] P. Flandrin, “Temps-fréquence,” Hermes, 1993.
- [76] L. Cohen and C. Lee, “Instantaneous frequency and time-frequency distributions,” in *Circuits and Systems, 1989., IEEE International Symposium on*, IEEE, 1989, pp. 1231–1234.
- [77] S. Mahmoud, Z. Hussain, I. Cosic, and Q. Fang, “Time-frequency analysis of normal and abnormal biological signals,” *Biomed. Signal Process. Control*, vol. 1, no. 1, pp. 33–43, 2006.
- [78] A. Poularikas, *Transforms and applications handbook*. CRC press, 2010.
- [79] L. COHEN and T. Posch, “Positive time-frequency distribution functions,” *IEEE Trans. Acoust.*, vol. 33, no. 1, pp. 31–38, 1985.
- [80] O. Auger, François and Flandrin, Patrick and Gonçalves, Paulo and Lemoine, “Time-frequency toolbox,” *CNRS Fr. Univ.*, p. 46, 1996.
- [81] A. Papandreou, “A unified framework for the scale covariant affine, hyperbolic, and power class quadratic time-frequency representations using generalized time shifts,” *Acoust. Speech, Signal Process. 1995. ICASSP-95., 1995 Int. Conf.*, vol. 2, pp. 1017–

- 1020, 1995.
- [82] G. F. Hlawatsch, Franz and Papandreou, Antonia and Boudreaux-Bartels, “The power classes of quadratic time-frequency representations: A generalization of the affine and hyperbolic classes,” in *Signals, Systems and Computers, 1993. 1993 Conference Record of The Twenty-Seventh Asilomar Conference on*, 1993, pp. 1265–1270.
- [83] A. Papandreou, “The hyperbolic class of quadratic time-frequency representations. I. Constant-Q warping, the hyperbolic paradigm, properties, and members,” *IEEE Trans. Signal Process.*, vol. 41, no. 12, pp. 3425--3444, 1993.
- [84] G. F. Hlawatsch, Franz and Papandreou-Suppappola, Antonia and Boudreaux-Bartels, “The hyperbolic class of quadratic time-frequency representations. II. Subclasses, intersection with the affine and power classes, regularity, and unitarity,” *IEEE Trans. Signal Process.*, vol. 45, no. 2, pp. 303–315, 1997.
- [85] K. M. Denes, Pablo and Wu, Delon and Dhingra, Ramesh and Pietras, Raymond J and Rosen, “The effects of cycle length on cardiac refractory periods in man,” *Circulation*, vol. 49, no. 1, pp. 32–41, 1974.
- [86] M. Portnoff, “Time-frequency representation of digital signals and systems based on short-time Fourier analysis,” *IEEE Trans. Acoust.*, vol. 28, no. 1, pp. 55–69, 1980.
- [87] S. Mallat, “A wavelet tour of signal processing: the sparse way,” Academic press, 2008.
- [88] J. Goswami and A. Chan, “Fundamentals of wavelets: theory, algorithms, and applications,” vol. 233, John Wiley & Sons, 2011.
- [89] O. Govrin, D. Sadeh, S. Akselrod, and S. Abboud, “Cross-correlation technique for arrhythmia detection using PR and PP intervals,” *Comput. Biomed. Res.*, vol. 18, no. 1, pp. 37–45, 1985.
- [90] “A comparison of the existence of cross terms’ in the Wigner distribution and the squared magnitude of the wavelet transform and the short-time Fourier transform,” *IEEE Trans. signal Process.*, vol. 40, no. 10, pp. 2498–2517, 1992.
- [91] W. J. Williams, “Recent advances in time-frequency representations: Some theoretical

- foundations,” IEEE Press Series in Biomedical Engineering, 1998.
- [92] A. Rosado Muñoz, “Desarrollo de Técnicas de Detección de Fibrilación Ventricular Basadas en Algoritmos Tiempo-Frecuencia,” Universitat de València, 2000.
- [93] L. Cohen, “Time-frequency analysis,” vol. 778, Prentice Hall PTR Englewood Cliffs, NJ:, 1995.
- [94] R. Latif, H. Aassif, A. Moudden, B. Faiz, and G. Maze, “The experimental signal of a multilayer structure analysis by the time-frequency and spectral methods,” *NDT E Int.*, vol. 39, no. 5, pp. 349–355, 2006.
- [95] G. Latif, R and Aassif, E and Moudden, A and Decultot, D and Faiz, B and Maze, “Determination of the cutoff frequency of an acoustic circumferential wave using a time–frequency analysis,” *NDT \& E Int.*, vol. 33, no. 6, pp. 373–376, 2000.
- [96] F. Hlawatsch, T. Manickam, R. Urbanke, and W. Jones, “Smoothed pseudo-Wigner distribution, Choi-Williams distribution, and cone-kernel representation: Ambiguity-domain analysis and experimental comparison,” *Signal Processing*, vol. 43, no. 2, pp. 149–168, 1995.
- [97] H. Choi and W. Williams, “Improved time-frequency representation of multicomponent signals using exponential kernels,” *IEEE Trans. Acoust.*, vol. 37, no. 6, pp. 862–871, 1989.
- [98] Z. Guo, L. Durand, and H. Lee, “The time-frequency distributions of nonstationary signals based on a Bessel kernel,” *IEEE Trans. Signal ...*, vol. 42, no. 7, pp. 1700–1707, 1994.
- [99] M. B. Messaoud, B. Khelil, and A. Kachouri, “Analysis and parameter extraction of P wave using correlation method,” *Int. Arab J. Inf. Technol.*, vol. 6, no. 1, pp. 40–46, 2009.
- [100] “Fast non-invasive ventricular fibrillation detection method using pseudo Wigner-Ville distribution,” in *Computers in Cardiology 2001*, IEEE, 2001, pp. 237–240.
- [101] M. Thomas, M. K. Das, and S. Ari, “Automatic ECG arrhythmia classification using dual tree complex wavelet based features,” *AEU - Int. J. Electron. Commun.*, vol. 69,

- no. 4, pp. 715–721, 2015.
- [102] P. Xia, T. Tahara, T. Kakue, Y. Awatsuji, K. Nishio, S. Ura, T. Kubota, and O. Matoba, “Performance comparison of bilinear interpolation, bicubic interpolation, and B-spline interpolation in parallel phase-shifting digital holography,” *Opt. Rev.*, vol. 20, no. 2, pp. 193–197, 2013.
- [103] J.-S. Wang, W.-C. Chiang, Y.-L. Hsu, and Y.-T. C. Yang, “ECG arrhythmia classification using a probabilistic neural network with a feature reduction method,” *Neurocomputing*, vol. 116, pp. 38–45, 2013.
- [104] J. M. Leiva Murillo, “Extracción de características mediante criterios basados en teoría de la información,” Universidad Carlos III de Madrid, 2007.
- [105] J. V. Valenzuela, “Interpolación de formas en imágenes usando morfología matemática,” *Informatica*, 2008.
- [106] Y.-C. Yeh, W.-J. Wang, and C. W. Chiou, “Feature selection algorithm for ECG signals using Range-Overlaps Method,” *Expert Syst. Appl.*, vol. 37, no. 4, pp. 3499–3512, 2010.
- [107] C. L. Huang and C. J. Wang, “A GA-based feature selection and parameters optimization for support vector machines,” *Expert Syst. Appl.*, vol. 31, no. 2, pp. 231–240, 2006.
- [108] Y. Liu and Y. F. Zheng, “FS\_SFS: A novel feature selection method for support vector machines,” *Pattern Recognit.*, vol. 39, no. 7, pp. 1333–1345, 2006.
- [109] O. Chapelle, B. Scholkopf, and A. Zien, “Semi-supervised learning (chappelle, o. et al., eds.; 2006)[book reviews],” *IEEE Trans. Neural Networks*, vol. 20, no. 3, p. 542, 2009.
- [110] M. Celebi and K. Aydin, “Unsupervised Learning Algorithms,” Springer, 2016.
- [111] L. Zhang, H. Peng, and C. Yu, “An approach for ECG classification based on wavelet feature extraction and decision tree,” in *2010 International Conference on Wireless Communications and Signal Processing, WCSP 2010*, IEEE, 2010, pp. 1–4.
- [112] M. Wiggins, A. Saad, B. Litt, and G. Vachtsevanos, “Evolving a Bayesian classifier for ECG-based age classification in medical applications,” *Appl. Soft Comput. J.*, vol. 8,

no. 1, pp. 599–608, 2008.

- [113] D. Gao, M. Madden, D. Chambers, and G. Lyons, “Bayesian ANN classifier for ECG arrhythmia diagnostic system: A comparison study,” in *Proceedings of the International Joint Conference on Neural Networks*, 2005, vol. 4, pp. 2383–2388.
- [114] Y.-C. Yeh, W.-J. Wang, and C. W. Chiou, “Cardiac arrhythmia diagnosis method using linear discriminant analysis on ECG signals,” *Measurement*, vol. 42, no. 5, pp. 778–789, 2009.
- [115] I. Saini, D. Singh, and A. Khosla, “QRS detection using K-Nearest Neighbor algorithm (KNN) and evaluation on standard ECG databases,” *J. Adv. Res.*, vol. 4, no. 4, pp. 331–344, 2013.
- [116] M. R. Homaeinezhad, S. A. Atyabi, E. Tavakkoli, H. N. Toosi, A. Ghaffari, and R. Ebrahimpour, “ECG arrhythmia recognition via a neuro-SVM-KNN hybrid classifier with virtual QRS image-based geometrical features,” *Expert Syst. Appl.*, vol. 39, no. 2, pp. 2047–2058, 2012.
- [117] J. Kim, H. Shin, K. Shin, and M. Lee, “Robust algorithm for arrhythmia classification in ECG using extreme learning machine,” *Biomedical*, vol. 8, no. 1, p. 31, 2009.
- [118] B. Yilmaz, E. Arikan, and M. Asyali, “Use of kNN and quadratic discriminant analysis methods for sleep staging from single lead ECG recordings,” in *Biomedical Engineering Meeting (BIYOMUT), 2010 15th National*, IEEE, 2010, pp. 1–4.
- [119] T. P. Kao, J. S. Wang, C. W. Lin, Y. T. Yang, and F. C. Juang, “Using Bootstrap AdaBoost with KNN for ECG-based automated obstructive sleep apnea detection,” *Neural Networks (IJCNN), 2012 Int. Jt. Conf.*, pp. 1–5, 2012.
- [120] R. Saini, N. Bindal, and P. Bansal, “Classification of heart diseases from ECG signals using wavelet transform and kNN classifier,” in *Computing, Communication & Automation (ICCCA), 2015 International Conference on*, IEEE, 2015, pp. 1208–1215.
- [121] W. J. Hwang and K. W. Wen, “Fast kNN classification algorithm based on partial distance search,” *Electron. Lett.*, vol. 34, no. 21, pp. 2062–2063, 1998.
- [122] C. Cortes and V. Vapnik, “Support-Vector Networks,” *Mach. Learn.*, vol. 20, no. 3, pp.

273–297, 1995.

- [123] F. Alonso-Atienza, E. Morgado, L. Fernandez-Martinez, A. Garcia-Alberola, and J. L. Rojo-Alvarez, “Combination of ECG parameters with support vector machines for the detection of life-threatening arrhythmias,” pp. 385–388, 2012.
- [124] S. S. Mehta and N. S. Lingayat, “SVM-based algorithm for recognition of QRS complexes in electrocardiogram Algorithm bas  sur le SVM pour reconnaître les QRS Complex dans l ’ ECG,” *IRBM*, vol. 29, no. 29, pp. 310–317, 2008.
- [125] S. Mehta and N. Lingayat, “Application of support vector machine for the detection of P-and T-waves in 12-lead electrocardiogram,” *Comput. Methods Programs Biomed.*, vol. 93, no. 1, pp. 46–60, 2009.
- [126] Y. Lee and O. Mangasarian, “SSVM: A smooth support vector machine for classification,” *Comput. Optim. Appl.*, vol. 20, no. 1, pp. 5–22, 2001.
- [127] S. Balasundaram and D. Gupta, “Lagrangian support vector regression via unconstrained convex minimization,” *Neural Networks*, vol. 51, pp. 67–79, 2014.
- [128] L. Breiman, “Bagging predictors,” *Mach. Learn.*, vol. 24, no. 2, pp. 123–140, 1996.
- [129] F. Alonso-Atienza, J. L. Rojo- lvarez, A. Rosado-Mu oz, J. J. Vinagre, A. Garc a-Alberola, and G. Camps-Valls, “Feature selection using support vector machines and bootstrap methods for ventricular fibrillation detection,” in *Expert Systems with Applications*, 2012, vol. 39, no. 2, pp. 1956–1967.
- [130] S. Kim, “An Interior-Point Method for Large-Scale Logistic Regression,” *J. Mach. Learn. Res.*, vol. 8, no. Jul, pp. 1519–1555, 2007.
- [131] A. Y. Ng, “Feature selection, L 1 vs. L 2 regularization, and rotational invariance,” *Twenty-first Int. Conf. Mach. Learn. - ICML ’04*, p. 78, 2004.
- [132] A. De Gaetano, S. Panunzi, F. Rinaldi, A. Risi, and M. Sciandrone, “A patient adaptable ECG beat classifier based on neural networks,” *Appl. Math. Comput.*, vol. 213, no. 1, pp. 243–249, 2009.
- [133] D. Patra, M. K. Das, and S. Pradhan, “Integration of Fcm, Pca and neural networks for classification of Ecg arrhythmias,” *IAENG Int. J. Comput. Sci.*, vol. 36, no. 3, pp. 24–

62, 2009.

- [134] F. J. Martínez-Estudillo, C. Hervás-Martínez, M. Torres-Jiménez, and A. C. Martínez-Estudillo, “Modelo no lineal basado en redes neuronales de unidades producto para clasificación. Una aplicación a la determinación del riesgo en tarjetas de crédito,” *Rev. Metod. Cuantitativos para la Econ. y la Empres.*, vol. 3, pp. 40–62, 2016.
- [135] P. A. Gutierrez Peña, “Nuevos Modelos de Redes Neuronales Evolutivas y Regresión Logística Generalizada utilizando Funciones de Base . Aplicaciones,” Universidad de Granada, 2009.
- [136] V. Labatut and H. Cherifi, “Accuracy measures for the comparison of classifiers,” *5th Int. Conf. Inf. Technol.*, no. May, p. 11, Jul. 2011.
- [137] M. and others Raedo, Maudes and Jesús, “Combinación de Clasificadores : Construcción de Características e Incremento de la Diversidad,” 2010.
- [138] X. Tang, N. Zhang, J. Zhou, and Q. Liu, “Hidden-layer visible deep stacking network optimized by PSO for motor imagery EEG recognition,” *Neurocomputing*, vol. 234, pp. 1–10, 2017.
- [139] Z. Masetic and A. Subasi, “Congestive heart failure detection using random forest classifier,” *Comput. Methods Programs Biomed.*, vol. 130, pp. 54–64, 2016.
- [140] W. Ben Johnson, P. J. Vatterott, M. A. Peterson, S. Bagwe, R. D. Underwood, A. J. Bank, R. M. Gage, B. Ramza, B. W. Foreman, V. Splett, T. Haddad, J. M. Gillberg, and S. Ghosh, “Body surface mapping using an ECG belt to characterize electrical heterogeneity for different left ventricular pacing sites during cardiac resynchronization: Relationship with acute hemodynamic improvement,” *Hear. Rhythm*, vol. 14, no. 3, pp. 385–391, 2017.
- [141] J. Gama and P. Brazdil, “Cascade generalization,” *Mach. Learn.*, vol. 41, no. 3, pp. 315–343, 2000.
- [142] D. Wolpert, “Stacked generalization,” *Neural networks*, vol. 5, no. 2, pp. 241–259, 1992.
- [143] F. Hoffmann, “Advances in Intelligent Data Analysis: 4th International Conference,

- IDA 2001, Cascais, Portugal, September 13-15, 2001. Proceedings,” vol. 4, 2001.
- [144] J. Mjahad, A and Rosado-Muñoz, A and Guerrero-Martínez, J and Bataller-Mompeán, M and Francés-Víllora, “ECG Analysis for Ventricular Fibrillation Detection Using a Boltzmann Network,” *VI Lat. Am. Congr. Biomed. Eng. CLAIB 2014, Paraná, Argentina 29, 30 \& 31 Oct. 2014*, pp. 532–535, 2015.
- [145] I. Jekova, “Shock advisory tool: Detection of life-threatening cardiac arrhythmias and shock success prediction by means of a common parameter set,” *Biomed. Signal Process. Control*, vol. 2, no. 1, pp. 25–33, 2007.
- [146] I. Jekova and V. Krasteva, “Real time detection of ventricular fibrillation and tachycardia,” *Physiol. Meas.*, vol. 25, no. 5, p. 1167, 2004.
- [147] Q. Li, C. Rajagopalan, and G. D. Clifford, “Ventricular fibrillation and tachycardia classification using a machine learning approach,” *IEEE Trans. Biomed. Eng.*, vol. 61, no. 6, pp. 1607–1613, 2014.
- [148] D. Xia, Q. Meng, Y. Chen, and Z. Zhang, “Classification of ventricular tachycardia and fibrillation based on the lempel-ziv complexity and EMD,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2014, vol. 8590 LNBI, pp. 322–329.
- [149] T. W. Chua and W. W. Tan, “Interval type-2 fuzzy system for ECG arrhythmic classification,” *Stud. Fuzziness Soft Comput.*, vol. 242, pp. 297–314, 2009.
- [150] P. Phong and K. Thien, “Classification of cardiac arrhythmias using interval type-2 TSK fuzzy system,” *Syst. Eng. 2009. KSE’09 ...*, 2009.
- [151] H. Xie, Z. Gao, and H. Liu, “Expert Systems with Applications Classification of ventricular tachycardia and fibrillation using fuzzy similarity-based approximate entropy,” *Expert Syst. Appl.*, vol. 38, no. 4, pp. 3973–3981, 2011.
- [152] L. Kaur and V. Singh, “Ventricular fibrillation detection using emprical mode decomposition and approximate entropy,” *Int. J. Emerg. Technol.*, vol. 3, no. 5, pp. 260–268, 2013.
- [153] A. Ibaida and I. Khalil, “Distinguishing between ventricular Tachycardia and

Ventricular Fibrillation from compressed ECG signal in wireless Body Sensor Networks,” *Eng. Med. Biol. Soc. (EMBC), 2010 Annu. Int. Conf. IEEE*, pp. 2013–2016, 2010.

## Índice de Figuras

Figura 1. Circulación sistémica y pulmonar de la sangre.....	20
Figura 2. Anatomía del corazón. ....	21
Figura 3. El ciclo cardíaco [4]. ....	23
Figura 4. Sistema de conducción cardíaco y sus ondas características [2].....	24
Figura 5. El potencial eléctrico de las células del miocardio, las flechas corresponden a los principales movimientos de iones a través de la membrana celular [6]. ....	25
Figura 6. Derivaciones de extremidades Einthoven (estándar). ....	29
Figura 7. Derivaciones de extremidades aumentadas de goldberger.....	30
Figura 8. Derivaciones precordiales del plano horizontal. ....	31
Figura 9. Modelo ideal del ciclo cardiaco. ....	32
Figura 10. Señal ECG de ritmo sinusal normal (ritmo).....	34
Figura 11. Extrasístoles ventriculares.....	37
Figura 12. Señal ECG con episodios de taquicardia ventricular. ....	37
Figura 13. Señal ECG con episodios de flutter ventricular. <b>¡Error! Marcador no definido.</b>	
Figura 14. Señal ECG con episodios de fibrilación ventricular. ....	39
Figura 15. Metodológica general seguida en este trabajo. ....	47
Figura 16. Filtrado pasa-banda IIR aplicado a señal ECG de tipo ‘Normal’, señal de entrada en color azul, señal de salida filtrada en color rojo, su respuesta en frecuencia. ....	52
Figura 17. Filtrado pasa-banda FIR aplicado a señal ECG de tipo ‘Normal’, señal de entrada en color azul, señal de salida filtrada en color rojo, su respuesta en frecuencia. ....	53
Figura 18. Descomposición de 3 niveles. ....	54
Figura 19. La señal original, representada en azul, y la señal de salida, representada en color rojo, y cómo elimina la fluctuación de la línea base empleando Wavelet madre de tipo sym4. ....	54
Figura 20. La parte superior presenta la señal original en color azul y la señal de salida en color rojo, mostrando la eliminación de la fluctuación de la línea base mediante el filtro de Media Móvil (N=31). En la parte inferior se presenta su respuesta frecuencial. ....	55

Figura 21. La señal original representada en azul, la señal de salida representada en color rojo y cómo elimina la fluctuación de la línea base mediante el filtro Mediana. ....	56
Figura 22. La señal original, representada en azul, y la señal de salida, representada en color rojo, y cómo elimina la fluctuación de la línea base mediante el filtro Smooth. .	57
Figura 23. El procedimiento para calcular las Marcas de Referencia de las Ventanas (MRV) mediante el algoritmo de detección de marcas y el algoritmo de corrección, y obtener las ventanas de tiempo. ....	58
Figura 24. Se presenta las etapas de procesado inicial de señal ECG de tipo ‘Normal’, ‘Otros’, ‘TV’ y ‘FV’. cada columna representa la misma etapa. de izquierda a derecha: señal original, etapa de eliminación de oscilación de línea base, puntos ML (puntos rojos). ....	60
Figura 25. Ejemplo espectro de potencia y la de distribución Pseudo-Wigner-Ville en tiempo y frecuencia de la señal ECG ‘Normal’ .....	66
Figura 26. Ejemplo de Distribución de Transformada corta de Fourier en tiempo y frecuencia de la señal ECG ‘normal’ .....	70
Figura 27. Ejemplo de Distribución de Transformada Wavelet en tiempo y frecuencia de la señal ECG ‘normal’ .....	71
Figura 28. Distribución de WVD de la señal ‘Normal’ procesadas directamente sin usar la transformada de Hilbert. ....	75
Figura 29. Distribución de WV de la señal analítica ‘Normal’ usando la transformada Hilbert. ....	75
Figura 30. Distribución de PWV de la señal analítica de ECG ‘Normal’ .....	76
Figura 31. Distribución de SPWVD de la señal analítica de ECG ‘Normal’ .....	78
Figura 32. Muestra las representaciones de tiempo-frecuencia de señal analítica de ECG ‘Normal’ mediante la aplicación de la técnica de Choi-Williams. ....	79
Figura 33. Representación de tiempo-frecuencia de la señal analítica de ECG ‘Normal’ mediante la distribución de Born-Jordan. ....	80
Figura 34. Representación de tiempo-frecuencia de la señal analítica de ECG ‘Normal’ mediante la Distribución de Bessel. ....	81
Figura 35. Diagrama de la etapa de extracción realizada para la detección de Fibrilación Ventricular. tras la RTF, se muestran las dos opciones de imagen extraída, sin reducción de datos, con dimensionalidad reducida y además la selección de características. ....	82

Figura 36. De arriba a abajo: las ventanas de señal originales y su correspondiente RTF e IRTF de tamaño 45x150 junto con la IRTF de tamaño reducido 3x5 para señales de tipo ‘Normal’, ‘Otros’, ‘TV’ y ‘FV’ (en columnas). .....	84
Figura 37. Técnicas de aprendizaje automático.....	89
Figura 38. Procedimientos de clasificación (etapa de la prueba). .....	97
Figura 39. Algoritmo de validación cruzada. ....	98
Figura 40. Esquema general de los procesos seguido aplicando los clasificadores individuales.....	101
Figura 41. Resultados para una iteración del entrenamiento y la prueba de un conjunto de datos asignados aleatoriamente mediante cinco clasificadores, usando la técnica de Análisis Continuo AC.....	104
Figura 42. Resultados para una iteración del entrenamiento y la prueba de un conjunto de datos asignados aleatoriamente mediante cinco clasificadores, usando la técnica de MRV. ....	109
Figura 43. Resultados para una iteración del entrenamiento y la prueba de un conjunto de datos asignados aleatoriamente mediante el algoritmos KNN, usando la técnica de reducción de datos MIP. ....	116
Figura 44. Fase de la prueba mediante la técnica SC. ....	119
Figura 45. Resultados para una iteración del entrenamiento y la prueba de un conjunto de datos asignados aleatoriamente mediante el algoritmos KNN, usando la técnica de reducción SC. ....	120
Figura 46. Método de clasificadores combinados en cascada.....	124
Figura 47. Método multclasificador de fusión en paralelo.....	125
Figura 48. Topología de multclasificador jerárquico. ....	125

## Índice de Tablas

Tabla 1. Conjunto de entrenamiento. ....	91
Tabla 2. Resultados de Sensibilidad (Sens), Especificidad (Esp) y Exactitud (Exa) de la detección de las patologías ('FV', 'TV') obtenidos por cinco algoritmos de clasificación, usando AC. ....	105
tabla 3. Resultados de sensibilidad, especificidad y exactitud de la detección de las patologías ('Normal', 'Otros') obtenidos por cinco algoritmos de clasificación, usando AC.....	106
Tabla 4. Resultados de sensibilidad, especificidad y exactitud de la detección de las patologías ('FV', 'TV') obtenidos por cinco algoritmos de clasificación, usando la técnica de MRV.....	110
Tabla 5. Resultados de sensibilidad, especificidad y exactitud de la detección de las patologías ('Normal', 'Otros') obtenidos por cinco algoritmos de clasificación, usando la técnica de MRV. ....	111
Tabla 6. Resultados de sensibilidad, especificidad y exactitud de la detección de las patologías ('FV', 'TV') obtenidos por el algoritmo KNN, usando varios tipos de RTF. ....	112
Tabla 7. Resultados de sensibilidad, especificidad y exactitud de la detección de las patologías ('Normal', 'Otros') obtenidos por el algoritmo KNN, usando varios tipos de RTF.....	113
Tabla 8. Resultados de sensibilidad, especificidad y exactitud de la detección de las patologías ('FV', 'TV') obtenidos por el algoritmo KNN, usando varias técnicas de filtros de la línea base y RTF de tipo PWV. ....	114
Tabla 9. Resultados de sensibilidad, especificidad y exactitud de la detección de las patologías ('Normal', 'Otros') obtenidos por el algoritmo KNN, usando varias técnicas de filtros de la línea base y RTF de tipo PWV. ....	114
Tabla 10. Resultados de sensibilidad, especificidad y exactitud de la detección de las patologías ('FV', 'TV') obtenidos por el algoritmo KNN, mediante los métodos RTF (45x150), IRTF de tamaños (45x150, 3x5). ....	117

Tabla 11. Resultados de sensibilidad, especificidad y exactitud de la detección de las patologías ('Normal', 'Otros') obtenidos por el algoritmo KNN, mediante los métodos RTF(45x150), IRTF de tamaños (45x150, 3x5).....	117
Tabla 12. Resultados de tiempo de ejecución medio para cada ventana de tiempo, obtenidos por el algoritmo de clasificación KNN mediante los métodos RTF(45x150), IRTF de tamaños (45x150, 3x5).....	118
Tabla 13. Resultados de sensibilidad, especificidad y exactitud de la detección de las patologías ('FV', 'TV') obtenidos por el algoritmo KNN, mediante los métodos SC de diferente tamaños $NC=\{15, 25, 50, 100\}$ . ....	121
Tabla 14. Resultados de sensibilidad, especificidad y exactitud de la detección de las patologías ('Normal', 'Otros') obtenidos por el algoritmo KNN, mediante los métodos SC de diferente tamaños $NC=\{15, 25, 50, 100\}$ . ....	121
Tabla 15. Resultados de tiempo de ejecución medio para cada ventana de tiempo, obtenidos por el algoritmo de clasificación KNN, mediante los métodos SC de diferente tamaños $NC=\{15,25,50,100\}$ . ....	122
Tabla 16. Resultados de sensibilidad, especificidad global y exactitud global de la detección de las patologías ('FV', 'TV') obtenidos por el método multclasificadores MMV, usando los datos de IRTF no reducida.....	126
tabla 17. Resultados de sensibilidad, especificidad global y exactitud global de la detección de las patologías ('Otros', 'Normal') obtenidos por el método multclasificador MMV, usando los datos de IRTF no reducida.....	127
Tabla 18. Resultados de tiempo de ejecución medio para cada ventana de tiempo, obtenidos por el método multclasificador de MMV, usando los datos de IRTF no reducida. ....	127
tabla 19. Resultados de sensibilidad, especificidad global y exactitud global de la detección de las patologías ('FV', 'TV') obtenidos por el algoritmo de combinacion MJ, usando los datos de IRTF no reducida.....	129
Tabla 20. Resultados de sensibilidad, especificidad global y exactitud global de la detección de las patologías ('Otros', 'Normal') obtenidos por el algoritmo de combinacion mj , usando los datos de IRTF no reducida.....	129
Tabla 21. Resultados de tiempo de ejecución medio para cada ventana de tiempo, obtenidos por el algoritmo de combinacion MJ, usando los datos de IRTF no reducida. ....	130

Tabla 22. Resultados de sensibilidad, especificidad global y exactitud global de la detección de las patologías ('FV', 'TV') obtenidos por el algoritmo de combinacion MJ , usando los datos de IRTF reducida mediante MIP.....	131
Tabla 23. Resultados de sensibilidad, especificidad global y exactitud global de la detección de las patologías ('Otros', 'Normal') obtenidos por el algoritmo de combinacion MJ, usando los datos de IRTF reducida mediante MIP.....	131
Tabla 24. Resultados de tiempo de ejecución medio para cada ventana de tiempo, obtenidos por el algoritmo de combinacion MJ, usando los datos de IRTF reducida mediante MIP. ....	132
Tabla 25. Resultados de sensibilidad, especificidad global y exactitud global de la detección de las patologías ('FV', 'TV') obtenidos por el algoritmo de combinacion MJ, usando SC.....	133
Tabla 26. Resultados de sensibilidad, especificidad global y exactitud global de la detección de las patologías ('Otros', 'Normal') obtenidos por el algoritmo de combinacion MJ, usando SC. ....	133
Tabla 27. Resultados de tiempo de ejecución medio para cada ventana de tiempo, obtenidos por el algoritmo de combinacion MJ, usando SC.....	134
tabla 28. Resultados de la sensibilidad, especificidad global y exactitud GLOBAL DE la detección de las patologías ('FV', 'TV') empleando los datos obtenidos mediante PWV usando las técnicas AC y MRV.....	136
Tabla 29. Resultados de sensibilidad, especificidad global y exactitud global de la detección de las patologías('FV', 'TV') y el tiempo de ejecución medio para cada ventana de tiempo empleando los datos obtenidos mediante PWV usando las técnicas reducción de los datos MIP y SC(NC=50).....	138
Tabla 30. Resultados de sensibilidad, especificidad global y exactitud global de la detección de las patologías ('FV', 'TV') y tiempo de ejecución medio para cada ventana de tiempo mediante la combinación de los algoritmos MJ empleando los datos obtenidos mediante IRTF, IRTF reducida (MIP), SC (NC=50). ....	139
Tabla 31. Resultados de sensibilidad, especificidad global y exactitud global de la detección de las patologías ('Otros', 'Normal') mediante la combinación de los algoritmos MJ empleando los datos obtenidos mediante IRTF, IRTF reducida (MIP), SC (NC=50).....	139

Tabla 32. Resultados de tiempo de ejecución medio para cada ventana de tiempo mediante la combinación de los algoritmos MJ empleando los datos obtenidos mediante IRTF, IRTF reducida (MIP), SC(NC=50)..... 140

Tabla 33. Resultados de sensibilidad, especificidad global y exactitud global de la detección de las patologías ('FV', 'TV') obtenidos para la clasificación de las arritmias cardiacas por el método propuesto en este trabajo y otros métodos..... 141

Tabla 34. Resultados de sensibilidad, especificidad y exactitud de la detección de las patologías ('Otros', 'Normal') obtenidos para la clasificación de las arritmias cardiacas por el método propuesto en este trabajo y otros métodos..... 142