

**UNIVERSIDAD AUTÓNOMA DE BAJA  
CALIFORNIA**

**MAESTRÍA Y DOCTORADO EN CIENCIAS E INGENIERÍA**

**FACULTAD DE INGENIERÍA**



**TESIS:**  
**Nuevo Modelo Clasificador de Arritmias No  
Supervisado**

**Que presenta para obtener el grado de  
MAESTRO EN CIENCIAS**

**TESISTA:**  
**MANUEL MARTINEZ CASAS**

**DIRECTOR Y CODIRECTOR DE TESIS:**  
**DR. ROBERTO LOPEZ AVITIA**  
**DR. MARCO A. REYNA CARRANZA**

**Noviembre de 2017**

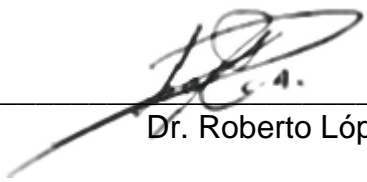
**RESUMEN** de la Tesis de Manuel Martínez Casas, presentada como requisito parcial para la obtención del grado de MAESTRO EN CIENCIAS.

Mexicali, Baja California, México. Noviembre de 2017.

## **Nuevo Modelo Clasificador de Arritmias No Supervisado**

Resumen aprobado por:

Avitia



---

Dr. Roberto López  
Director de tesis

### **RESUMEN**

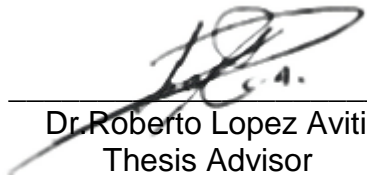
De acuerdo con la Organización Mundial de la Salud, las enfermedades cardiovasculares (ECV) son la principal causa de muerte en el mundo. Se estima que 17,5 millones de personas murieron a causa de las enfermedades cardiovasculares en 2012, lo que representa el 31% de todas las muertes a nivel mundial. El electrocardiograma (ECG) es una herramienta central para el pre-diagnóstico de las enfermedades del corazón. Muchos de los avances en materia de clasificación de arritmias ECG se han desarrollado en el siglo pasado; sin embargo, todavía hay investigación para identificar formas de onda malignas en los tiempos ECG. Se conocen los complejos ventriculares prematuros (PVC) que se asocia con arritmias ventriculares malignas y en los casos de muerte súbita cardíaca (SCD). La detección de este tipo de arritmia ha sido crucial en aplicaciones clínicas. En este trabajo, se extrajeron 80 características diferentes de 108,653 ECG latidos de anuncios de la base de datos MIT-BIH para ser evaluado en un nuevo tipo de clasificador no supervisado que permite detectar latidos de tipo normal, PVC y otro tipo de latidos de ECG.

Palabras clave: Electrocardiograma (ECG), Complejos Ventriculares Prematuros (PVC), Clasificador de arritmias no supervisado.

**ABSTRACT** of the thesis, presented by Manuel Martinez Casas, in order to obtain the MASTER of Science DEGREE. Mexicali, Baja California, México. November 2017.

## **A Novel Non-Supervised Model and Arrhythmias' Classifier**

Approved by:



---

Dr. Roberto Lopez Avitia  
Thesis Advisor

### Abstract

According to the World Health Organization, cardiovascular diseases (CVD) are the main cause of death worldwide. An estimated 17.5 million people died from CVD in 2012, representing 31% of all global deaths. The electrocardiogram (ECG) is a central tool for the pre-diagnosis of heart diseases. Many advances on ECG arrhythmia classification have been developed in the last century; however, there is still research to identify malignant waveforms on ECG beats. The premature ventricular complexes (PVC) are known to be associated with malignant ventricular arrhythmias and in sudden cardiac death (SCD) cases. Detecting this kind of arrhythmia has been crucial in clinical applications. In this work, we extracted 80 different features from 108,653 ECG classified beats of the MIT-BIH database and we developed a novel non-supervised classifier for ECG beats classification as the Normal, PVC and other kind of ECG beats.

Keywords: Electrocardiogram (ECG), Premature Ventricular Contraction (PVC), Arrhythmia classifier.

## **AGRADECIMIENTOS**

Este trabajo y resultados fueron posibles por un conjunto de personas e instituciones que han puesto en mi camino un propósito y metas futuras para convertirme en una mejor persona.

Agradezco primeramente a la Facultad de Ingeniería de la Universidad Autónoma de Baja California por todos estos años, tanto en licenciatura y maestría, por la disposición de recursos humanos y materiales para convertirme en el profesional que soy ahora.

Al Consejo Nacional de Ciencia y Tecnología por la beca otorgada.

Al cuerpo académico de Bioingeniería que pusieron en mí los cimientos científicos e ingenieriles, en particular al Dr. Miguel Bravo, Dr. Fernando Solís, Dra. Aseneth Herrera, y en especial al Dr. Roberto López Avitia, que fungió como mi tutor tanto en licenciatura y posgrado, por su apoyo en estos años.

Al Dr. Marco Carranza por sus continuas observaciones durante cada final de semestre y al Dr. Fernando González por sus valiosas clases, consejos y retroalimentaciones por parte de la rama de inteligencia artificial y aprendizaje máquina que espero dedicarme ahora en adelante.

A mis compañeros y amigos dentro del Laboratorio de Bioingeniería. A Alejandro Amezquita por ser contrapeso en mis ideas y por sus oportunas ideas durante nuestra investigación. A Alexandra Caraveo por ayudarme con este proceso burocrático y tedioso de titulación ahora que me encuentro fuera de Mexicali, y a Alba Refojo, gracias por creer en mí, en mi intelecto y en mi persona.

Al Dr. Jugal Kalita que me recibió en la Universidad de Colorado – Colorado Springs, por confiar en mi capacidad y objetivo del proyecto.

A Guadalupe Ortega y Francisco Torres, por recibirme en Colorado Springs y darme la más grande y calurosa bienvenida que haya tenido. Su apoyo, siempre incondicional, y su calidez humana fueron claves en mi estancia en Colorado Springs, sin ellos no hubieran ocurrido tales resultados.

Para finalizar, a mi hermana Marymeli, que estuvo ayudándome durante mi licenciatura haciendo posible el ingreso a este posgrado, a mi tía Mónica Casas y a mi madre María Casas, quienes con amor, tolerancia y principalmente paciencia han visto por mi bienestar e impulsado mi crecimiento personal y profesional.

Por último, a mi abuelita María Jesús, por ser ejemplo de ser humana, pilar en mí y personas claves en mi vida.

## Contenido

LISTA DE TABLAS.....	7
LISTA DE FIGURAS .....	8
I. OBJETIVO GENERAL .....	9
I.I OBJETIVOS ESPECÍFICOS .....	9
1. INTRODUCCIÓN.....	10
2. HIPÓTESIS.....	13
3. MARCO TEORICO .....	14
3.1 Fisiología cardiaca.....	14
3.2 Actividad Eléctrica del Corazón .....	18
3.3 El Electrocardiograma (ECG).....	20
3.4 Arritmias .....	25
3.5 Enfermedades cardiovasculares y sus consecuencias.....	30
3.6 Métodos de ayuda al diagnóstico por computadora.....	32
4. ANTECEDENTES.....	35
5. METODOLOGÍA .....	40
5.1 Ambiente de programación y bases de datos .....	40
5.2 Bases de datos públicas .....	41
5.3 Algoritmos .....	42
5.3.1 Preprocesamiento de la señal ECG .....	43
5.3.2 Aglomeración .....	50
5.3.3 Desarrollo de Descriptores .....	56
5.3.4 Proporciones y etiquetado de clase .....	64
5.4 Experimentación .....	66
6. RESULTADOS.....	72
7. DISCUSIÓN.....	80
8. CONCLUSIÓN .....	83
REFERENCIAS .....	84

## **LISTA DE TABLAS**

TABLA I EJEMPLO DE SEÑAL ECG EN AGLOMERADOS Y SUS DESCRIPTORES	64
TABLA II RESULTADOS DEL EXPERIMENTO DE REPRODUCIBILIDAD DE MAK	73
TABLA III SELECCIÓN DE TOPOLOGÍA MAK	74
TABLA IV SELECCIONAR LAS MEJORES TRES CARACTERÍSTICAS	74
TABLA V SELECCIONAR LOS MEJORES CONJUNTOS DE CARACTERÍSTICAS	76
TABLA VI COMOPARATIVA DE RESULTADOS CON TRABAJOS SIMILARES	79

## LISTA DE FIGURAS

Figura 1 Estructura del corazón y flujo de sangre por la cámaras del corazón. Tomado de Llamedo	15
<i>Figura 2 Circulación de la sangre por el cuerpo transportando oxígeno y recibiendo sangre pobre en oxígeno. Tomada de Sheerwood.</i>	17
<i>Figura 3 Fluctuaciones de iones de sodio, potasio y calcio para la activación del potencial de acción</i>	19
Figura 4 Muestra que la actividad eléctrica cardíaca es la suma total de todos los potenciales de acción de las diferentes zonas del corazón. Tomado de Llamedo.	21
Figure 5 Relación de la señal de ECG y la acción de bombeo física del corazón. Tomada Sheerwood.	24
Fig 6 Ilustración del algoritmo	43
Figura 7 Representación esquemática de la implementación eficiente de la transformada discreta wavelet por medio de cascadas de filtros FIR	44
Figura 8 Remoción de ruido de baja frecuencia que altera la línea basal de la señal ECG.	46
Figura 9 Ejemplo de señal ECG y sus anotaciones.	48
Figura 10 Ventana de tiempo tomado para cada latido en las señales ECG	49
Figura 11 Extracción de latido y creación de matriz de trabajo para su posterior análisis y clasificación	50
Figura 12 Vista extensa del paso "Grupos y descriptores" del algoritmo propuesto	52
Figura 13 comparación de latidos etiquetados con LAT y LDT	59
Figura 14 Ilustración de las diferentes funciones de decisión cambiando los hiperparámetros en el algoritmo de MSVUC	63
Figura 15 Histograma mostrando el F-score para LoV los 109 pacientes de la base de datos que contiene al menos 40 latidos de origen ventricular	82

## **I. OBJETIVO GENERAL**

Crear un algoritmo que no requiere asistencia de un experto, no supervisado que identifique los latidos arrítmicos de origen ventricular de los latidos de origen supraventricular dentro de la señal de ECG de pacientes individuales por medio de técnicas de aprendizaje máquina.

### **I.I OBJETIVOS ESPECÍFICOS**

- Explorar y describir el patrón que presentan las señales con latidos arrítmicos.
- Implementar técnicas computacionales para crear una representación condensada de las señales ECG y el patrón de los latidos.
- Hacer uso de los modelos de aprendizaje máquina que exploren y encuentren el patrón de los latidos arrítmicos dentro de la señal de ECG.

## 1. INTRODUCCIÓN

Las arritmias cardiacas han sido reconocidas como una complicación clave en las enfermedades del corazón desde hace mucho tiempo [1, 2]. Generalmente se conoce a las arritmias cardiacas como las condiciones en las cuales la actividad cardiaca del corazón es muy lenta, o muy rápida o muy irregular [3]. Estos cambios pueden provocar que la actividad eléctrica en las aurículas o ventrículos se vuelva turbulento, convirtiéndose dentro de las principales causas de morbilidad y mortalidad, incluida la muerte súbita cardiaca, particularmente en los países industrializados [4]. En México, las enfermedades cardiovasculares representan la causa número uno de defunciones, así mismo es una de las principales en el estado de Baja California [5, 6].

En ocasiones la detección de arritmias se necesita la monitorización 24 horas por medio de un monitor Holter que se encarga de tomar la señal electrocardiográfica (ECG), este puede registrar más de 100 000 latidos de un paciente. Siendo realistas, un médico sólo puede mirar a una fracción de estos datos. Esto ha llevado a los investigadores a desarrollar algoritmos para analizar automáticamente estos datos [7].

Los dispositivos que se utilizan para monitorizar el ECG contienen implementados algoritmos matemáticos para la detección de arritmias, así de como otros padecimientos que se puedan identificar; sin embargo, se ha demostrado que las conclusiones de estos modelos tienen altos porcentajes de error en diferentes diagnósticos [8]. Afortunadamente, continuamente se

sigue avanzando en los modelos para la clasificación y detección temprana de arritmias y otras enfermedades cardiovasculares [9].

Existe una especial atención en la detección de contracciones prematuras ventriculares y auriculares, ya que éstas arritmias son precursoras de arritmias que podrían llevar a una muerte súbita o son indicativas de una enfermedad cardiovascular grave [10,11]. Por lo tanto, la detección de estas anomalías en el ritmo cardiaco es un tema que se sigue investigando y se continúa proponiendo algoritmos y modelos matemáticos que ayuden al diagnóstico médico.

Una de los puntos más importantes es la forma de atacar el problema. Existen dos aproximaciones aceptables: metodologías intra e inter pacientes [12].

Al contrario de trabajos como en [13-27] que mezclan latidos del mismo paciente en los conjuntos de entrenamiento, validación y prueba, obteniendo altos porcentajes de clasificación, los trabajos reportados con anterioridad [28-31] realizan el procedimiento inter-pacientes y tienen un rendimiento mucho más bajo que en otros [13-27], debido a que no existe información del mismo paciente entre los conjuntos de entrenamiento, validación y prueba. La razón es que estos trabajos reflejan la dificultad real de detectar los latidos y los resultados involucran la inevitable variabilidad entre pacientes.

En [32], se menciona que los modelos clasificadores generales o por metodología inter-pacientes son pocos fiables y no son extensamente usados en práctica. Una alternativa es la metodología intra-paciente, ya que el patrón de un solo paciente es mucho más fácil que el patrón combinado de varios

pacientes. Estos trabajos requieren una cierta cantidad de latidos previamente etiquetados por un médico experto para entrenar el algoritmo.

Resumiendo, parece ser que hasta ahora no ha sido posible superar el problema que presenta la variabilidad entre paciente para entrenar clasificadores generales de latidos. La guía experta de un médico es necesaria para desarrollar un modelo que se adapte al paciente. Esto quiere decir que, en el futuro, otros médicos tengan la necesidad de etiquetar de nuevo otros latidos para mantener el algoritmo trabajando y actualizado ya que la señal cardiaca puede cambiar con respecto al tiempo en forma y frecuencia cardiaca.

En este trabajo, presentamos una nueva metodología la cual aporta un acercamiento sin supervisión para clasificar entre latidos de origen supraventricular (LoSV), formado por los latidos tipo normal y arritmia supraventricular, y de origen ventricular (LoV), formado por los tipos de arritmia ventricular y de fusión. Esta aproximación no requiere la asistencia médica, ya que trata de capturar el patrón en la señal y está desarrollado en base a las observaciones hechas al buscar un patrón general en las señales.

## **2. HIPÓTESIS**


El latido arrítmico de origen ventricular puede diferenciarse de los latidos de origen supra ventricular mediante el análisis del patrón de trazo ECG de cada paciente y con modelos matemáticos no supervisados que agrupen los latidos de dicha señal, para posteriormente identificarlos con descriptores derivados de la misma.

### **3. MARCO TEORICO**

#### **3.1 Fisiología cardiaca.**

El corazón del ser humano es el órgano encargado de transportar la sangre a todo el cuerpo a través del aparato circulatorio aportando al homeostasis con el transporte de oxígeno y dióxido de carbono, nutrientes y hormonas que provienen y van hacia las células. También ajusta la temperatura y pH, provee defensas ante enfermedades por medio la producción de anticuerpos.

Mientras que el órgano cardiaco se considera como una unidad, los lados derecho e izquierdo funcionan como dos bombas biológicas. Estas mitades, derecha e izquierda, cada una tiene dos cavidades, una superior y otra inferior. Las cavidades superiores, reciben el nombre de aurículas, las cuales reciben sangre que regresa al corazón y la pasan a las inferiores, los cuales se conocen como ventrículos, que tienen la tarea de empujar la sangre ya sea hacia los pulmones o al sistema circulatorio periférico.



**Figura 1.** Estructura del corazón y flujo de sangre por las cámaras del corazón.


Los vasos sanguíneos que regresan la sangre desde los tejidos a las aurículas se les llama venas, mientras que las que transportan la sangre desde los ventrículos son arterías. Existe una partición muscular entre las mitades del corazón, la cual impide que la sangre entre las cavidades se mezcle. Siendo de extrema importancia ya que por un lado se tiene sangre rica en oxígeno, mientras que el otro tiene sangre rica en dióxido de carbono la cual será transportada a los pulmones para existe un intercambio gaseoso.

La sangre que regresa de la circulación sistemática ingresa al corazón por medio de la aurícula derecha a través de dos venas principales, las venas cavas. Èsta sangre ha retornado desde tejidos del cuerpo, donde el oxígeno se ha utilizado y se agregó dióxido de carbono. La sangre parcialmente

desoxigenada entra a la aurícula derecha y de aquí al ventrículo derecho donde es bombeada hacia los pulmones mediante la arteria pulmonar, la cual se divide en dos ramas donde cada una desemboca en los pulmones. Entonces, el lado derecho del corazón retoma la sangre de la circulación sistemática y la transporta hacia la circulación pulmonar.

Una vez en los pulmones, antes de ser regresada a la aurícula izquierda a través de las venas pulmonares, se produce el intercambio gaseoso y se le suministra de oxígeno a la sangre a cambio de la pérdida del dióxido de carbono.

La sangre rica en oxígeno regresa a la aurícula izquierda donde será llevada al ventrículo izquierdo, donde este tiene la importante misión de bombear la sangre hacia todos los sistemas del cuerpo, con excepción a los pulmones. Por lo tanto, el lado izquierdo del corazón recibe la sangre de la circulación pulmonar y la impulsa a la circulación sistemática. La arteria aorta es el único vaso sanguíneo por donde sale la sangre desde el ventrículo izquierdo. Después se dividen en otras ramas para abastecer a los órganos del cuerpo.



**Figura 2.** Circulación de la sangre por el cuerpo transportando oxígeno y recibiendo sangre pobre en oxígeno. Tomada de Sheerwood.

En comparación a la circulación pulmonar, donde toda la sangre fluye a través de los pulmones, la circulación sistemática se asemeja a una serie de rutas paralelas. Una parte de la sangre bombeada desde el ventrículo izquierda va a los riñones, otra al cerebro, a los músculos, y así continuamente. Quiere decir que cada órgano del cuerpo recibe sangre rica en oxígeno sin que antes tenga que pasar por otro sistema. Las células de los tejidos de cada órgano y sistema utilizan el oxígeno para oxidar los nutrientes para la obtención de energía, creando y desechando dióxido de carbono el

cual será añadido a la sangre. Posteriormente, la sangre parcialmente desoxigenada y provista de dióxido de carbono como producto, retornará a la aurícula derecha del corazón, completándose un circuito.

### **3.2 Actividad Eléctrica del Corazón**

Para bombear la sangre se requiere de los potenciales de acción que provocan el encogimiento de las células musculares cardíacas. Éstas células tienen una propiedad llamada autoritmicidad, siendo está la capacidad de generar potenciales de acción por sí mismas, contrayendo rítmicamente el corazón.


Existen en el músculo cardíaco dos tipos de células:

a) Células contráctiles: Tienen la tarea fundamental de realizar la contracción. Constituyen el 99% de las células del músculo cardíaco y normalmente no inician potenciales de acción por ellas mismas.

b) Células autorítmicas: Sin facultad de realizar trabajo mecánico, pero siendo especiales para iniciar los potenciales de acción que conllevan al encogimiento de las células contráctiles.

Al comparar las células autorítmicas cardíacas no tienen un potencial de reposo como las células nerviosas y musculo-esqueléticas, las cuales

mantienen un potencial de reposo hasta cuando una célula es excitada. En vez de esto, se observa una actividad de marcapasos, esto quiere decir que su potencial de membrana se despolariza lentamente hasta alcanzar un umbral, originando así un nuevo potencial de acción.



**Figura 3.** Fluctuaciones de iones de sodio, potasio y calcio para la activación del potencial de acción

Vínculos complicados que involucran varios y diferentes mecanismos iónicos son los encargados del potencial de acción. Los flujos de iones más importantes para que se lleve a cabo el potencial de marcapasos son:

- a) Aumento de la corriente  $Na^+$  hacia dentro de la membrana
- b) Disminución de la corriente  $K$  hacia el exterior de la membrana
- c) Aumento de la corriente  $Ca^{2+}$  a la membrana.

### **3.3 El Electrocardiograma (ECG)**


Las corrientes iónicas creadas por el miocardio en los ciclos de despolarización y repolarización viajan por los tejidos circundantes del corazón a través de los fluidos corporales. Una pequeña parte de ésta actividad iónica logra extenderse hasta la superficie del cuerpo, consiguiéndose revelar usando electrodos registro. La señal obtenida se le llama electrocardiograma o ECG.

El ECG es un registro complejo que simboliza la acción global de la actividad iónica del órgano cardíaco durante las fases de despolarización y repolarización. Por lo tanto, no es un registro de un potencial en específico de una única célula en un tiempo determinado. La señal en un punto específico representa la suma neta de la actividad conjunta iónica de todas las células musculo-cardíaco, siendo algunas activadas y otras están por ser excitadas.

La señal electrocardiográfica es también la comparación entre dos distintos puntos de voltaje detectado por los electrodos sobre la piel. La forma de onda de la actividad registrada está en función de la colocación de los electrodos en los que se está midiendo.

Con el fin de realizar un examen estándar, los registros de ECG son por medio de 12 señales seleccionadas a través de una colocación de electrodos aceptada en todos los procedimientos. Cada señal registrada por la diferencia de potencial entre dos electrodos se le llama derivación. Mientras

que entre mayor información se tenga, se puede resolver tener una mayor certeza de las conclusiones derivadas, generalmente para detectar anomalías en el conducto eléctrico del corazón una sola derivación es suficiente. La segunda derivación es usada comúnmente por los médicos para identificar obstrucciones en el paso iónico en el corazón.[wiens thesis]



**Figura 4.** Muestra que la actividad eléctrica cardíaca es la suma total de todos los potenciales de acción de las diferentes zonas del corazón. Tomado de Llamedo.

Descifrar la información implicada en el ECG está en manos de un conocimiento completo de la cadena de propagación de la actividad cardíaca y también de la posición del corazón en función de la ubicación de los electrodos. El electrocardiograma normal tiene tres ondas sobresalientes: la onda P, el complejo QRS y la onda T.

La onda P representa la despolarización auricular, mientras que el complejo QRS es la despolarización ventricular, y la onda T es la

repolarización ventricular. Dado que la despolarización y repolarización incitan el ciclo de encogimiento y descanso del corazón, respectivamente, los sucesos mecánicos rítmicos del corazón se encuentran levemente atrasados a los cambios de la actividad iónica registrada por los electrodos en el ECG.

Para un mejor entendimiento del ECG hay que tomar en cuenta lo siguiente:

1. La excitación del nodo SA no crea la actividad iónica necesaria para alcanzar la superficie del cuerpo, por lo tanto, no existe registro de la onda de despolarización de este nodo. Entonces, la primera onda, la onda P, se origina por la onda de despolarización se extiende por medio de las aurículas.

2. En un ECG normal, no es apreciable ninguna onda de la repolarización auricular ya que el complejo QRS y ésta actividad iónica ocurren en forma sincrónica siendo oculta por el complejo.

3. La amplitud de la onda P es menor que la del complejo QRS porque éste último tiene una densidad muscular mucho más grande que el de las aurículas y consecuentemente una actividad iónica mayor.

4. Existen tres puntos en el tiempo donde no hay un flujo iónico dentro del miocardio, haciendo que ocurra una línea basal en el trazo del ECG:


- a) En la remisión del nodo AV. Este retardo es visto entre la parte final de la onda P y el comienzo del complejo QRS; se le

conoce como segmento PR, llamado así ya que en muchas ocasiones no existe o la amplitud de la onda Q no es significativa en comparación de la onda R).

b) Otra línea basal característica es el segmento ST, presentándose ya que los ventrículos estén en completa despolarización y las células encargadas del encogimiento se encuentren en la fase de meseta de su potencial de acción. El segmento ST se localiza al final del complejo QRS y al inicio de la onda T. Durante este tiempo se realizó la excitación completa de los ventrículos, siendo estos contraídos y vaciados de sangre. Hay que tomar en cuenta el segmento ST no refleja la actividad contráctil, que el ECG es un registro de la actividad iónica que resulta en una actividad muscular cardíaca posterior.

c) Una vez que el miocardio ha sido totalmente repolarizado, el llenado sanguíneo de los ventrículos se encuentra en proceso, ocurriendo una vez terminada la onda T y anteriormente a la onda P sucesiva, siendo el lapso intervalo TP.

Ya que la excitación iónica provoca el ciclo mecánico cardíaco, por lo general patrones extraños registrados en el ECG conducen a una actividad contráctil anormal. Entonces, el análisis de los patrones en el ECG puede reflejar información valiosa sobre el estado del corazón.



**Figure 5.** Relación de la señal de ECG y la acción de bombeo física del corazón. Tomada Sheerwood.

Las razones principales de la ocurrencia de un registro anormal son desviaciones en el ritmo cardiaco, latidos extraños y miopatías cardíacas.

- a) Dependiendo de la distancia entre dos picos R contiguos, se puede determinar si la frecuencia cardíaca es normal o no.

b) Los latidos extraños o regularidad de las ondas características y sus segmentos es cualquier variación de lo que se como normal y se le conocen como arritmias. Existen varias fuentes de origen como focos ectópicos (impulso iónico fuera del sistema de conducción normal), variación en la excitación del nodo SA, u obstrucción con la conducción de la onda despolarizante, también por consecuencia el ritmo cardíaco es alterado.

c) Las formas de ondas principales pueden proporcionar un reconocimiento y evaluación de alguna miopatía cardíaca.

### **3.4 Arritmias**

Las arritmias se definen como cualquier ritmo cardíaco que no sea el ritmo sinusal normal. El ritmo sinusal se origina en el nodo SA y posteriormente se lleva a cabo a tasas adecuadas a través de las aurículas, nodo AV, y el sistema de conducción intraventricular, es decir, las ramas de Purkinje. En reposo la descarga del nodo SA tiende a ser regular, a pesar de que generalmente se presenta ligeras variaciones. En los adultos en reposo la velocidad del ritmo sinusal normal oscila entre 60 y 100 latidos por minuto.

Por lo tanto, un ritmo sinusal más de 100 latidos por minuto (taquicardia sinusal) y menores de 60 (bradicardia sinusal) se pueden considerar las arritmias. Sin embargo, debe tenerse en cuenta que el ritmo sinusal varía a lo largo de un periodo de 24 horas y la taquicardia sinusal y

bradicardia sinusal generalmente son una respuesta fisiológica simpática (ejercicio, estrés) o (descanso, sueño) de estímulos parasimpáticos. Por otra parte, un diagnóstico de la arritmia en sí mismo no significa patología evidente. De hecho, en sujetos sanos, se observa con frecuencia la presencia esporádica de ciertas arritmias ambas (complejos prematuros) activas y (complejos de escape, cierto grado de bloqueo nodo AV, arritmia sinusal evidente, etc.) pasivas.

De acuerdo con el sitio de origen: En arritmias supraventriculares (incluidos aquellos que tienen su origen en las aurículas y en la intersección AV) y las arritmias ventriculares.

Debido al aumento de la automaticidad, la reentrada, o desencadenamiento de la actividad iónica generan complejos prematuros aislados o repetitivos en el ECG. Los complejos prematuros aislados pueden ser originados en un foco ectópico ya sea parasistólico o extrasistólico. El mecanismo extrasistólico presenta un acoplamiento de intervalos fijos, mientras que el parasistólico es una variedad de acoplamientos de intervalos.

Complejos prematuros de origen supraventricular generalmente son seguidas por un corto complejo QRS, aunque pueden ser amplio si se conducen con aberración. La onda P ectópica menudo no se ve fácilmente, ya que puede estar oculto en la onda T precedente. En otros casos, el impulso auricular prematuro permanece bloqueado en el nodo AV, iniciando una pausa en vez de un complejo QRS prematuro. Los complejos prematuros de origen ventricular no están precedidos por una onda P ectópica, y el complejo QRS

es siempre amplia ( $>120$  ms), a menos que se originen en los extremos de las ramas de Purkinje dentro del ventrículo. Complejos prematuros y repetitivos incluyen todos los tipos de taquiarritmias supraventriculares o ventriculares (taquicardias, fibrilación, aleteos). En arritmias cardíacas activas, debido a los mecanismos de reentrada, existe un bloqueo unidireccional en alguna parte.

Los mecanismos de las arritmias cardíacas son a menudo los resultados de muchos factores, incluyendo la fluctuación en la concentración intracelular de Ca, después de corrientes de despolarización, períodos refractarios más largos o cortos, por el sistema nervioso, la dispersión de la repolarización, y los cambios en la excitabilidad y la conducción.

Los latidos ectópicos podrían surgir de marcapasos fuera del nódulo sinusal, como resultado de un aumento anormal de la ritmicidad en el sistema de Purkinje ventricular.

Extrasístoles auriculares (APB) se ve con frecuencia en individuos normales y tienen poca importancia clínica. Estos también se observan en la insuficiencia cardíaca, y de vez en cuando, puede ser una señal temprana de la irritabilidad auricular que puede progresar a una más seria arritmia auricular.

En APBs los complejos QRS son normales ya que se propagan normalmente a través de los ventrículos a través del sistema de conducción. Las ondas P son generalmente un poco anormales, ya que se originan a partir de un foco anormal, y se propagan en un patrón anormal. El impulso generalmente invade el área del nodo SA y restablece el marcapasos sinusal.

APB que ocurren muy pronto tras el latido previo realizado, probablemente conducidos de una manera aberrante, con frecuencia con una configuración bloqueo de haz de rama derecha. Una conducción aberrante es particularmente probable cuando la APB sigue un largo intervalo RR ( el fenómeno Ashman ). Si un latido APB es muy temprano se puede ejecutar en el tejido refractario en el nodo AV y puede no ser conducido.

Los latidos ectópicos ventriculares (VPB ) se originan en algún lugar de los ventrículos. El QRS ancho ( complejos más grandes de 0.12 segundos ) y extraño. Algunos VPB pueden exhibir acoplamiento en latidos normales anteriores. Pueden ocurrir antes o después dentro del ciclo. El mecanismo de PVC puede ser reentrada o actividad desencadenada como se discutió previamente. Algunos PVC parecen no mostrar ningún acoplamiento fijo hasta en los latidos normales. Si muestran un ritmo regular, pueden ser el resultado de un foco parasistólico. Teniendo en cuenta que algunas despolarizaciones parasistólicas experimentan "bloqueo de salida " y resultan en una excitación ventricular. Latidos ectópicos ventriculares parasistólicos suelen considerarse relativamente benignos. La mayoría de los VPBs son seguidos por una pausa.

La pausa es generalmente de compensación, lo que significa que el intervalo de acoplamiento al ritmo normal de precedente más la pausa después de la VPB comprenden un intervalo igual al doble del intervalo normal de R-R. Un VPB interpolado está entre dos complejos QRS normales que llegan a tiempo con la activación normal del seno auricular.

Los VPB se encuentran a menudo en individuos sanos y en caso de que sean infrecuentes, probablemente tienen una importancia menor. En insuficiencia cardíaca, VPB pueden ser un factor de riesgo para el aumento de la incidencia de arritmias ventriculares más graves y muerte súbita. VPBs pueden ocurrir por separado o en grupos y se ha propuesto el siguiente orden de gravedad de acuerdo a la actividad ectópica ventricular:

1. Ocasional: menos del 30 VPB por hora de la misma morfología.
2. Frecuente: mayor que 30 por VPB uniformes hora o bigeminismo donde cada otro latido es un VPB
3. VPB multiforme: Diferentes morfologías QRS
4. VPB apareados: pares de VPB consecutivos
5. Taquicardia ventricular: de tres o más VPB
6. Aleteo ventricular: taquicardia ventricular rápida con una configuración sinusoidal causada por la fusión de la actividad QRS y Ts
7. fibrilación ventricular: Actividad eléctrica caótica sin QRS definidos.

Los VPB ocurren muy tempranamente en el ciclo cardíaco tanto que entran a la onda T del latido previo considerándose particularmente peligrosos. En el momento que corresponde al pico de la onda T, el miocardio ventricular está empezando a repolarizar. Algunas células pueden estar en el período relativamente refractario, mientras que otras pueden ser más plenamente recuperadas, y otras en periodo refractario. Las propiedades

eléctricas del miocardio son por lo tanto muy variadas, y puede existir condiciones que favorezcan bucles de reentrada. Por lo tanto, un estímulo adicional en la forma de un VPB aislado, muy temprano en el ciclo, puede desencadenar un ritmo de latidos ventriculares ectópicos repetitivos tales como taquicardia ventricular o fibrilación ventricular. El período de cerca del pico de la onda T se refiere a menudo como el período vulnerable. Una correcta caracterización de la actividad ectópica ventricular requiere un largo plazo ( 24 horas ) de monitorización.

La clasificación de la frecuencia cardiaca en el ECG como se puede ver, es una tarea importante para el análisis automático de las arritmias. Esta es la primera tarea realizada por un cardiólogo al inspeccionar una grabación, y como se muestra arriba, es una tarea muy exigente.

### **3.5 Enfermedades cardiovasculares y sus consecuencias.**

Según la Organización Mundial de la Salud, las enfermedades cardiovasculares (ECV) representan la primera causa de muerte en el mundo. Un estimado de 17.5 millones de personas murieron por ECV en el 2012, representando el 31% [33]. En México, de acuerdo al INEGI, desde 1998 al 2011 las defunciones por esta causa presentaron tasas que fluctúan de 70.7 al 97.0 por 100,000 habitantes, predominando la enfermedad isquémica con una tasa de 65.6 por 100,000 habitantes: donde el mayor número de defunciones se presenta en hombres, y en el caso de Baja California en 2011,

se encuentra como la principal causa de mortalidad en la población de edad reproductiva (15 a 64 años) [5]. Por otro lado, datos reportados por INEGI 2012, de las 14,756 muertes en el estado de Baja California, el 19% están relacionadas con esta causa [6].

De acuerdo a la última pauta en la Asociación Americana del Corazón (American Heart Association AHA) sobre arritmias ventriculares y muerte súbita cardíaca del 2006, la epidemiología de las arritmias ventriculares abarca una serie de descriptores de riesgo y aplicaciones clínicas, que van desde complejos prematuros ventriculares y taquicardia ventricular no sostenida en sujetos normales a muerte súbita debido a taquiarritmias ventriculares en pacientes con y sin cardiopatía estructural [34].

Un estudio en el 2007 determinó que alrededor del 40-50% de las muertes por causas de problemas cardiovasculares fueron muerte súbita y alrededor de 80% de éstas experimentaron taquiarritmia ventricular. Lo que nos muestra que cerca de 6 millones de defunciones son por arritmias ventriculares mortales [35].

En la última actualización de estadística de la AHA sobre enfermedades cardíacas e infartos cerebrales en el 2014 [10], las arritmias supraventriculares pueden provocar miocardiopatías, así como fungir de disparador de muerte súbita. Así mismo, de 150 pacientes consecutivos con

taquicardia estudiada por electrofisiología invasiva, 122 fueron taquicardia ventricular mientras que los restantes fueron taquicardia supraventricular [10].

Aunque el pronóstico de taquicardias ventriculares o contracciones ventriculares prematuros (PVC) recurrentes en la ausencia de fallo cardiaco estructural es buena [36], una cardiomiopatía reversible puede desarrollarse en pacientes con PVC frecuentes [37][38] y en algunos casos muerte súbita cardiaca se ha atribuido a algunos PVC acoplados [39][40].

Durante monitoreo ambulatorio cardiaco, la llamada taquiarritmia ventricular polimórfica (TVP) se presentó entre 0.01% a 0.15%, sin embargo, en los pacientes que sufrieron muerte cardiaca súbita, TVP se presentó en 30% a 40% de los casos [41, 42 y 43]. Mientras quienes sufrieron un infarto al miocardio, se presentó del 1.2% al 2% [44 y 45]. Fuera del hospital, se estima que TVP se presentó alrededor de 25% de todos los casos de muerte súbita que involucran taquicardia ventricular [46 y 47].

### **3.6 Métodos de ayuda al diagnóstico por computadora.**

El electrocardiograma (ECG) es una herramienta central para el diagnóstico de enfermedades cardíacas. Hoy en día, el análisis asistido por computadora de corto plazo ECG, grabaciones en reposo en posición supina, el quirófano o la UCI es un procedimiento bien establecido. Un problema

importante, sin embargo, es rastrear la presencia y la cantidad de arritmias durante días, semanas y meses. Como los cardiólogos no pueden pasar su tiempo en el análisis de millones de latidos del corazón por un solo paciente, se hace necesario de un algoritmo automatizado [7].

Se han hecho grandes avances en la eliminación de ruido, detección de ondas características, la variabilidad del ritmo cardíaco análisis y, recientemente, incluso alguna clasificación de las formas de ECG. Como los algoritmos son cada vez más potentes y precisos, las brechas entre los avances algorítmicos recientes y la metodología de las pruebas disponibles han comenzado a emerger [9].

En los primeros días de la computación científica se hicieron los primeros intentos de traducir los procesos de toma de decisiones de un médico en reglas duras para una computadora [48]. Dos décadas más tarde, el rendimiento computacional era lo suficientemente alto como para intentar emular el razonamiento cardiólogos mediante árboles de decisión [49]. En los años noventa, clasificadores de ECG florecieron y grandes mejoras surgieron en la calidad y fiabilidad [50].

A finales de los años noventa, Silipo y Marchesi [51] formularon una nueva meta para la década siguiente: "Por lo tanto, el diseño de bajo costo, alto rendimiento y fácil de usar, y el equipo portátil para electrocardiografía, que ofrece una combinación de características de diagnóstico, parece ser un

objetivo que es muy valioso. Dicho equipo debe incorporar e integrar varias técnicas de análisis de datos, tales como procesamiento de señales, detección de patrones y reconocimiento, apoyo a la decisión, y la interacción con el usuario".

Las grabaciones a largo plazo necesarias para responder a estas preguntas tienen una gran cantidad de datos que no pueden ser tratados por un médico. Desafortunadamente, clasificadores desarrollados para el análisis a corto plazo en entornos de restricciones no funcionan bien en este escenario a largo plazo. Ruido debido en la línea de basal, el ruido muscular, desconexión de señal y así sucesivamente plantean una grave amenaza para los clasificadores. Por otra parte, el diagnóstico de registro automatizado a largo plazo se ve muy afectado por errores de clasificación. En grabaciones cortas de alrededor de 100 latidos, 95% de precisión produce 5 errores de clasificación, que son potencialmente detectadas por el médico. En las grabaciones a largo plazo se pierde el médico como una red de seguridad.

Los latidos 100,000 veces en un día típico. Por lo tanto, un clasificador tal produciría 5000 clasificaciones erróneas. Esto haría que las investigaciones mencionadas en la distribución de la arritmia inviable [50].

## 4. ANTECEDENTES

Ha habido un numero significativo de estudios [13-27] que utilizan herramientas matemáticas para rastrear la presencia de arritmias en el ECG.

El preprocesamiento incluye los clásicos filtros digitales para remover el ruido en la línea basal, ruido en altas frecuencias y por línea eléctrica. Los trabajos se enfocan en encontrar características únicas para encontrar el patrón de los latidos de una forma más eficiente. Características comunes involucran el intervalo R-R o frecuencia cardiaca, normalización de la frecuencia cardiaca, características estadísticas como la media, desviación estándar, máximo, mínimo, asimetría, transformaciones no líneas, coeficientes de la transformada discreta de wavelet (TDW), la presencia de ondas e intervalos característicos de los latidos como la onda P o la duración del complejo QRS conocidos ampliamente en el campo médico. Se han utilizado la mayoría de los algoritmos comunes de clasificación supervisada.

En particular, las Máquina de Soporte Vectorial (MSV) con el kernel de función de base radial (FBR) y diferentes tipos de Redes Neuronales (RN) han sido usadas extensivamente por tener la habilidad de crear funciones de decisión no lineales entre clases. Técnicas no supervisadas como Análisis de Componentes Principales (ACP), Análisis de Componentes Independientes (ACI), Análisis Factorial (AF), Mapas Auto-Organizados de Kohonen (MAK) han sido también usados con el fin de reducir la dimensionalidad de las características. Otros trabajos también incluyen análisis de aglomerados

como K-means, Mezcla de Gaussianas, Aglomerado Jerárquico para auxiliar en el proceso de la clasificación supervisada.

Uno de los puntos más importantes es la forma de aproximar el problema. Existen dos maneras aceptables de abordar el problema, metodologías intra e inter pacientes [32], además de la forma de clasificar los latidos.

La Asociación para el Avance de la Instrumentación Médica (AAMI, por sus siglas en inglés) provee de guías para clasificar los latidos de una señal de ECG en latidos normales, latidos supraventriculares, latidos ventriculares, latidos de fusión y latidos sin clasificar [28,29]. No obstante, la presencia de los dos últimos tipos de latidos es casi nula comparándolas con los latidos normales, supraventriculares y ventriculares. En trabajos recientes, generalmente no se toman como un tipo de latido, sino que los latidos de fusión se engloban en los latidos ventriculares y los pacientes con un gran número de latidos sin clasificar y/o sus latidos son removidos para pruebas, trabajando nada más con latidos normales, supraventriculares y ventriculares.

Trabajos reportados utilizan la propuesta inter-pacientes [28-31]. El rendimiento es mucho más bajo que en [13-17] porque no existe información del mismo paciente entre los conjuntos de entrenamiento, validación y prueba. Sin embargo, estos trabajos reflejan la real dificultad ya que los resultados involucran la inevitable variabilidad entre pacientes.

Por estas razones, existen pocos trabajos publicados de ésta manera. Chazal *et al.* [28] trabajó extrayendo características en el dominio del tiempo como el ritmo cardíaco y descriptores de onda de las dos señales disponibles de cada paciente de las grabaciones de la base de datos del MITBIH, para posteriormente dividir las señales de los pacientes en entrenamiento y prueba, sin mezclar información del mismo paciente entre los sets. Utilizó el clasificador bayesiano Discriminante Linear (DL) obteniendo mejores resultados que sus predecesores. Llamedo *et al.* [29] presentó otro clasificador global usando los mismos pacientes de la base de datos del MITBIH en el set de entrenamiento y prueba que Chazal *et al.* [28] pero incluyó en su trabajo dos bases de datos más para obtener tener más resultados y mejores conclusiones de su implementación. Él uso el ritmo cardíaco y características extraídas de la transformada discreta wavelet. Además, puso a prueba diferentes conjuntos de características y dos diferentes clasificadores bayesianos quedándose con el clasificar de Discriminante Linear. Llamedo *et al.* [52] modificó el trabajo pasado para poder incluir más de dos derivaciones, utilizando las mismas características y clasificador. La base de datos necesaria fue la INCART que contiene las 12 derivaciones estándar. Usando todas las derivaciones, él pudo mejorar su trabajo anterior, desafortunadamente es la única base de datos disponibles con éste número de derivaciones y etiquetadas. Ye *et al.* [53] trabajó en clasificar todos los tipos de arritmias en la base de datos de MITBIH y aparte clasificando de acuerdo a la AAMI. Utilizó características morfológicas de los coeficientes de la TDW e implementó el ACI a cada latido, teniendo matrices de alta dimensionalidad

las cuales redujo con el algoritmo de ACP. Una vez reducido, introdujo el ritmo cardíaco como característica. Él utilizó el clasificador MSV y combinó las dos derivaciones de la base de datos del MITBIH. Una vez que las características fueron extraídas, él primeramente mezcló información de pacientes tanto en los sets de training y prueba obteniendo resultados casi perfectos, es decir cercanos al 100%. Después probó su metodología entrenando y probando como en Chazal *et al.* [28] y Llamedo *et al.* [29,52] bajando el rendimiento (“performance”) significativamente por la variabilidad entre pacientes. Los resultados son comparables con los de Chazal *et al.* [28] y Llamedo *et al.* [29,52]. Mar *et al.* [31] principalmente trabajó en la selección de características para clasificar señales de ECG y probó un número considerable de características del dominio del tiempo, morfología de la onda, características estadísticas y del espacio tiempo-frecuencia usando la transformada discreta de wavelet. El algoritmo denominado Búsqueda Secuencial Flotante hacia Adelante lo utilizó para saber cuáles características son relevantes en conjunto con el clasificador bayesiano de Discriminante Lineal. Una vez que las características óptimas fueron extraídas, se utilizó un clasificador perceptrón multicapa. Los resultados fueron comparados con los trabajos de Chazal *et al.* [28], Llamedo *et al.* [29,52] y Ye *et al.* [30] pero con las características seleccionadas. Es importante mencionar que el en sensibilidad y valor positivo predictivo de cada clase varía considerablemente dependiendo de la aproximación.

En [32], es mencionado que los modelos clasificadores generales son pocos fiables y no son extensamente utilizados en la práctica. Una alternativa

es la metodología inter-paciente, ya que el patrón de un solo paciente es mucho más fácil que el patrón combinado de varios pacientes. Estos trabajos requieren una cierta cantidad de latidos previamente etiquetados por un médico experto para entrenar el algoritmo. Trabajos presentados en [28-34] obtienen resultados arriba de 95% en casi todos los casos, algunas cerca del 100% en valores predictivos verdaderos y sensibilidad cuando se trata de clasificar los latidos de acuerdo al estándar del AAMI. Solamente Llamedo *et al.* [53] y Al Rahhal *et al.* [54] presentan resultados sin entrenamiento previo del mismo paciente o ayuda médica. Llamedo *et al.* [53] modifica sus trabajos anteriores en [29,52], un clasificador general, incluyendo el algoritmo K-means, un modelo no supervisado. Esta modificación mejora el rendimiento (“performance”) de sus trabajos anteriores y permite que un experto contribuya en el resultado del algoritmo. El resultado final es cerca del 95% con la ayuda del médico.

Al Rahhal *et al.* [54] utiliza clasificación activa usando una aproximación de aprendizaje profundo. Utilizan el algoritmo “Autoencoder” para representar la señal en una menor dimensión en conjunto con el ritmo cardiaco para ser parte de las características. Al final un función “softmax” es entrenada en la RN con los mismos pacientes como en Chazal *et al.* [28], Llamedo *et al.* [28,52,53], Ye *et al.* [30] y Mar *et al.* [31]. Sus resultados, con la ayuda de un médico experto, es cerca del 100% con un número significativo de latidos previamente etiquetados del mismo paciente. Wiens *et al.* [32] compara el resultado de su algoritmo desarrollado en base de aprendizaje activo con un

software de HAMILTON, este software se implementa en base a reglas y tiene la ventaja que no requiere información previa o latidos previamente etiquetados del mismo paciente, pero solo reconoce latidos ventriculares prematuros. El algoritmo de Wiens *et al.* [32] fue mejor que el de HAMILTON con una cantidad de latidos etiquetados del mismo paciente.

Resumiendo, parece ser que hasta ahora no ha sido posible superar el problema que presenta la variabilidad entre paciente para entrenar clasificadores generales de latidos. La guía experta de un médico es necesaria para desarrollar un modelo que se adapte al paciente. Esto quiere decir que, en el futuro, otros médicos tengan la necesidad de etiquetar de nuevo otros latidos para mantener el algoritmo trabajando y actualizado ya que la señal cardiaca puede cambiar con respecto al tiempo en forma y frecuencia cardiaca.

## **5. METODOLOGÍA**

De acuerdo a nuestros experimentos, la metodología trabaja mejor cuando existen cuando menos 40 latidos de origen ventricular. Este trabajo es una primera aproximación para consecuentemente separar los latidos normales y las arritmias de origen supraventricular en un trabajo futuro.

### **5.1 Ambiente de programación y bases de datos**

La presente propuesta está hecha con los paquetes de simulación Matlab y Python 2.7, utilizando las paqueterías de SOM Toolbox para la

aplicación de los MAK. En caso de Python 2.7, las paqueterías PyWavelet y Sciki-learn se utilizaron para usar la TDW y algoritmos de aprendizaje máquina en los que se incluye la normalización, estandarización y otros algoritmos.

## **5.2 Bases de datos públicas**

En esta tesis se utilizaron tres bases de datos públicas del sitio de Physionet, las cuales son: (1) MIT-BIH arrhythmia database (MITBIH), que consiste de 48 señales de dos derivaciones con una duración de media hora por cada grabación. Una frecuencia de muestreo de 360 muestras por segundo y una resolución de 11 bits. Las anotaciones de cada latido fueron hechas por dos cardiólogos expertos, (2) MIT-BIH Supraventricular Arrhythmia database (SUPRA), hecha de 78 pacientes diferentes, cada una de 30 minutos y dos derivaciones con una frecuencia de muestreo de 120 Hz. Las anotaciones fueron primeramente hechas en automático y después corregidas por un estudiante de medicina y (3) St. Petersburg Instituto of Cardiological Technics 12-lead Arrhythmia database (INCART), compuesta de 75 señales con sus respectivas etiquetas por cada latido. Cada grabación contiene las 12 derivaciones a una frecuencia de muestreo de 257 Hz y una duración de 30 minutos.

### 5.3 Algoritmos

El algoritmo propuesto requiere de una serie de pasos de preprocesamiento y procesamiento para agrupar los latidos de origen supraventricular (LoSV) y latidos de origen ventricular (LoV). En la figura 6 se muestra una ilustración de alto nivel de las diferentes etapas del algoritmo. La primera etapa se realiza la limpieza y extracción de datos, por lo tanto, la señal del paciente es preprocesada y cada latido es extraído para formar una matriz en la cual se trabaja. La parte medular es la llamada Grupos y descriptores, debido a que se forman los grupos en base a algoritmos de aglomerados.

Una vez que los latidos están en conjuntos, se derivan descriptores de la información recabada de la señal ECG para caracterizar cada uno de estos aglomerados. El proceso de etiquetado y clasificación, se realiza en la etapa 3 donde los descriptores forman una serie de proporciones por cada grupo, y si estos descriptores alcanzan cierto umbral, el aglomerado se clasifica como latidos de origen supraventricular, de otra manera, son latidos de origen ventricular. Ésta clasificación binaria es relevante por dos razones fundamentales: (1) clínicamente la detección de latidos de origen ventricular es más importante, ya que puede comprometer la capacidad y eficiencia del corazón para bombear sangre y (2) la distinción de latidos ventriculares como paso previo facilitaría la clasificación de latidos normales y arritmias supraventriculares, ya que otras características podrían ser desarrolladas específicamente para ésta tarea debido a que la complejidad es mucho mayor entre estos tipos de latidos.

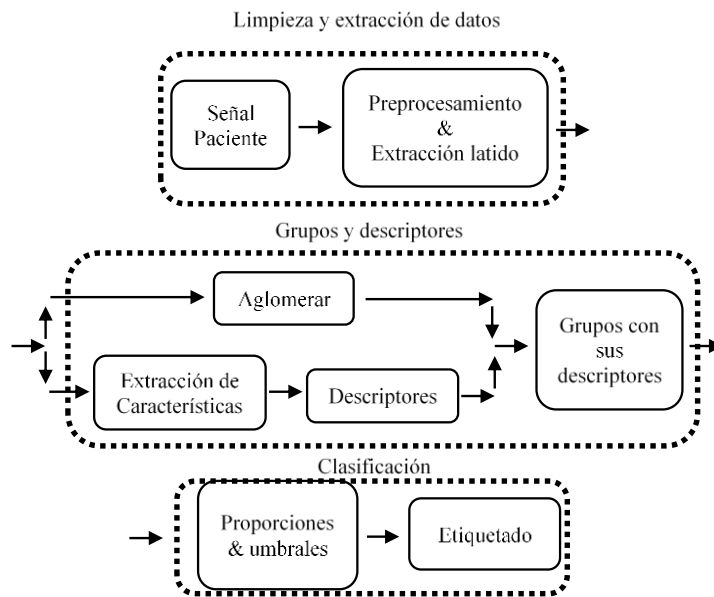


Figure 6. Ilustración de alto nivel del algoritmo propuesto.


Tres importantes suposiciones son reflejadas en el algoritmo: a) Con un número significativo de LoV, el algoritmo de aglomerado es capaz de separar los LoV y LoSV. b) si la tendencia calculada a partir del ritmo cardiaco o de los intervalos R-R, casi todos los latidos encima de la tendencia son de LoSV, c) en el espacio de las características, los LoSV están muy cercas uno del otros, mientras que los LoV están esparcidos.

Estas suposiciones se usan para calcular los descriptores y subsecuentes proporciones para etiquetar cada aglomerado.

### 5.3.1 Preprocesamiento de la señal ECG

Es muy común que la señal de ECG contenga ruido que comprometa el análisis. El preprocesamiento de la señal busca remover este tipo de

perturbaciones. El paso más común es eliminar el ruido de baja frecuencia encargada de mover la línea basal de la señal ECG. Para esto, la transformada discreta de wavelet es utilizada con el fin de aislar la energía de baja frecuencia que provoque la perturbación de la línea basal y una vez extraída se reconstruye la señal limpia. La TDW tiene ventajas sobre la clásica transformada de Fourier (TF) y la Transformada de Tiempo Corto de Fourier (TTCF), ya que TF representa el contenido general de energía y frecuencia, pero no en el tiempo que se presenta y TTCF requiere una ventana de tiempo para aplicar la transformada, comprometiendo la resolución en frecuencia y tiempo. La TDW soluciona estos problemas. Por medio de la convolución de una señal wavelet escalable con la señal original, se puede crear una representación escala-tiempo de múltiples resoluciones. Cuando la señal wavelet es comprimida, la resolución en tiempo se mejora permitiendo detección de cambios bruscos. Por otra parte, si la señal es extendida, energías en bajas frecuencias son capturadas. En otras palabras, comprimiendo y extendiendo la señal wavelet y convolucionándola con la señal original en el dominio del tiempo, la TDW puede detectar cambios en tiempo y frecuencia.



**Figura 7** Representación esquemática de la implementación eficiente de la transformada discreta wavelet por medio de cascadas de filtros FIR

La figura 7 muestra la implementación eficiente de la TDW, utilizando una cascada de filtros y submuestreo. La entrada de estos filtros es la señal muestreada de ECG y la salida es una serie de coeficientes de la TDW. La TDW descompone la señal en coeficientes de una variedad de frecuencias. Cada vez que la señal se descompone, es llamada una octava de resolución, donde cada octava es hecha por un par de filtros FIR. Estos filtros consisten en pasa-bajas (FPB) y pasa-altas (FPA). Dependiendo de la wavelet a usar, los filtros tienen sus propios coeficientes para descomponer la señal y reconstruirla. Después de cada filtrado, un submuestreo es hecho para hacer la transformación eficiente. El FPB produce la señal media, mientras que el FPA produce la señal detallada. El análisis de multiresolución es hecho cuando la señal media se convierte en la entrada de otro par de filtros para crear otra señal media y detallada en la siguiente octava. Cada par de filtro es representado por las ecuaciones:

$$A[n] = \sum_{k=0}^K LPF[k]x[n - k] \quad (1)$$

$$D[n] = \sum_{k=0}^K HPF[k]x[n - k] \quad (2)$$

Y el submuestreo puede ser visto como:

$$Ao[n] = A[2n] \quad (3)$$

$$Do[n] = D[2n] \quad (4)$$

Donde  $Ao$  es la señal media en un octavo nivel,  $Do$  es la señal detallada por un nivel de octava, mientras que  $LPF$  y  $HPF$  son los coeficientes de los filtros pasa-bajas y pasa-altas respectivamente.


Debido a la submuestreo sucesivo por dos, la señal tiene que tener una longitud al exponente de dos, para que sea eficiente computacionalmente. El

largo de la señal determina el número de niveles que la señal puede ser descompuesta. Por ejemplo, la señal con una longitud de 1024, puede ser descompuesta 10 niveles.

La reconstrucción de la señal puede ser hecha realizando el procedimiento anterior en un orden inverso, es decir, primero interpolar por 2, seguido de los filtros pasa-altas o pasa-bajas, ya sea el caso, y después se suman las señales siguientes para reconstruir al nivel requerido. Empero, si los filtros no son ideales pasa-mitad, entonces una perfecta reconstrucción no es posible.

Bajo ciertas condiciones es posible encontrar unos tipos de filtros que puedan proveer una reconstrucción perfecta. Los más famosos, y usados en este trabajo, son los desarrollados por Ingrid Daubechies, y son conocidos como wavelets Daubechies.

Nosotros, en base a [24], utilizamos la wavelet Daubechies 6 para descomponer la señal en sus respectivos coeficientes. En la siguiente figura 8 se puede apreciar una señal de ECG con perturbación en la línea basal y la eliminación del ruido.



**Figura 8** Remoción de ruido de baja frecuencia que altera la línea basal de la señal ECG. A) Muestra una señal ECG con ruido. B) Se muestran los coeficientes de la transformada discreta wavelet y el ruido de baja frecuencia. C) Reemplazar con ceros el coeficiente removido. D) Señal reconstruida sin el ruido de baja frecuencia que altera la línea basal.


Se extrajo hasta la novena octava, es decir, la señal paso por 9 cascadas de filtros. En la parte **B** se puede ver los coeficientes y acomodados desde la novena octava hasta la primera octava. El ruido de baja frecuencia correspondiente a la perturbación de la línea basal es claramente visto en la novena octava por su tendencia. Para remover este ruido, la reconstrucción es hecha reemplazando con ceros la parte correspondiente de los coeficientes de la novena octava. La reconstrucción sin el ruido de baja frecuencia se puede apreciar en la última imagen de la figura 8.

Un paso común es escalar la información para ayudar a prevenir dependencia de grandes valores en ciertas variables cuando se implementan en algoritmos de aprendizaje máquina. Los datos se transforman generalmente entre -1 a 1 o 0 a 1. Para métodos en base a distancias, escalar los datos ayuda a prevenir que los pesos en cada una de las variables se distribuyan de una mejor manera, de otra forma las variables con grandes valores tendrían pesos más significativos que otras que igualmente podrían ser importantes en el análisis. La normalización está hecha por la siguiente ecuación:

$$y[n_i] = \frac{x[n_i] - x_{min}}{x_{max} - x_{min}} \quad (5)$$

Donde  $x[n_i]$  corresponde a la muestra  $i$  de la señal  $x[n]$ ,  $x_{max} = \max(x[n])$  es el valor máximo de la señal  $x[n]$  y  $x_{min} = \min(x[n])$  es el valor mínimo de la señal  $x[n]$ . Cada señal fue normalizada entre valores cero y uno.

Para extraer los latidos se utiliza el archivo de anotaciones con la que viene cada señal de cada paciente. Proporciona en que muestra se encuentra el latido en tiempo y que tipo de latido es. Generalmente, se localiza en el pico R o muy cercano a éste. La figura 9 da referencia una porción de la señal y que tipo de latido es cada uno de los que se muestran



**Figura 9** Ejemplo de señal ECG y sus anotaciones.

A partir de la muestra del latido de interés, se toma una ventana de tiempo de 0.33 segundo a la izquierda y otra de 0.4 segundos a la derecha, como se aprecia en la figura 10.

Para el caso de la base de datos del MITBIH se toma 119 muestras hacia la izquierda y 144 muestras hacia la derecha, para la SUPRA son 42 a izquierda y 51 a la derecha, y para INCART son 85 a la izquierda y 103 a la derecha.

Finalmente, para los casos de las señales de las base de datos de SUPRA e INCART, donde las frecuencias de muestre son 128 y 257, respectivamente. Se hace un sobre muestreo a 360 Hz, similar a la base de datos del MITBIH como se recomienda en [55], esto con el fin de que todas las matrices que contengan los latidos de los pacientes tenga la misma

longitud y además que se dice que es una frecuencia de muestreo adecuada para la clasificación de latidos.





Figura 10 Ventana de tiempo tomado para cada latido en las señales ECG

Para sobremuestrear se realiza la interpolación por un factor  $N$ , dependiendo de la longitud deseada de la señal, seguido por un filtro pasa baja con frecuencia de corte  $F_c = \frac{0.5}{N}$ . Como en [55], la implementación está hecha en Matlab con la función “*resample*”, la cual utiliza por defecto un filtro FIR de decimo orden.

Cada latido compuesto por una ventana de tiempo se presenta como un vector  $x_i$ . Cada uno de estos vectores conformarán la matriz  $X(N \times s)$ , donde  $N$  será el número de latido en la señal y  $s$  el número de muestras que conforman el latido. Siendo ésta la matriz que se utiliza para detectar los tipos de latidos que conforman la señal de ECG.



**Figura 11** Extracción de latido y creación de matriz de trabajo para su posterior análisis y clasificación

### 5.3.2 Aglomeración

La sección de Grupos y descriptores es considerada la parte medular de esta aportación, en ella se combina aprendizaje no supervisado, detección de novedad y procesamiento de señal como se observa en la figura 12.

Naturalmente, como ésta aproximación es no supervisada y no requiere etiquetas de un experto, un algoritmo no supervisado es utilizado para agrupar los latidos dependiendo de la forma de onda reduciendo el problema de clasificar los grupos en LoSV o LoV, en vez de clasificar cada uno de los latidos. El algoritmo implementado para agrupar los latidos es el Mapas Auto-organizados de Kohonen (MAK), siendo este un arreglo de neuronas o pesos conectado en una red de una sola capa, en muchos casos en red de dos dimensiones. Lo que caracteriza a los MAK es la competencia suave entre neuronas en la capa de salida, donde una neurona ganadora y sus vecinos son actualizados en cada iteración de entrenamiento. Los MAK

son capaces de distinguir irregularidades y similitudes en las entradas, y una vez que la red esta entrenada es capaz de predecir respuestas con respecto a las entradas que alimentan a la red ya entrenada. Las neuronas de los MAK se acercan físicamente unas a otras en la red cuando reconocen grupos similares en las entradas. De esta manera, los MAK aprenden distribuciones y topologías de los vectores de entrada. Como generalmente la salida es una red de dos dimensiones, los MAK mapean la información  $R^n$  sobre una red bidimensional. Las neuronas pueden ser vistas también como nodos referencias  $i$  en la red, en otras palabras, una red  $m_i \in R^n$  tiene asociada un numero  $i$  de nodos. Los nodos del arreglo o neuronas pueden tener distintas topologías, regularmente son rectangulares o hexagonales.

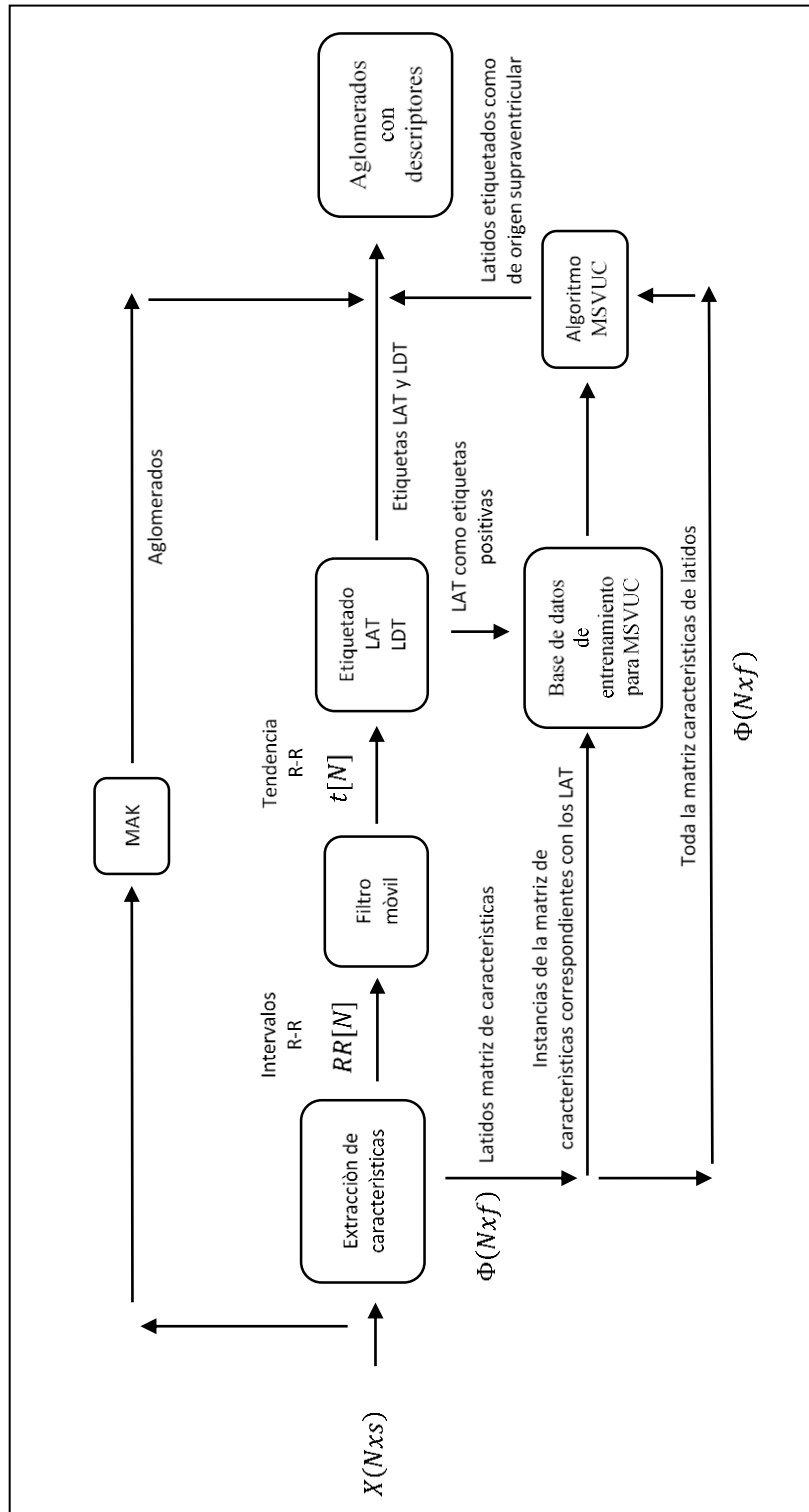


Figura 12 Vista extensa del paso "Grupos y descriptors" del algoritmo propuesto

Las entradas en este caso serán cada latido o vector  $x$  que conforman la matriz  $X(N \times s)$ , son comparadas con el valor de cada neurona y la más cercana se selecciona, entonces la entrada se mapea y se asocia a esa neurona que su a vez está en la red bidimensional. Los MAK pueden ser vistas como proyecciones no líneas de una entrada de alta dimensión en una presentación bidimensional. Usualmente la distancia Euclidiana se utiliza para comparar las entradas con las neuronas de referencia en la red. Para calcular la neurona ganadora  $c$  es:

$$c = \arg \min_i \{\|x - m_i\|\} \quad (6)$$

Y  $x$  es mapeado sobre la neurona  $c$ .

Los nodos topográficamente cercanos en el arreglo también aprenderán de la misma entrada. La fórmula que actualiza la red es:

$$m_i(t + 1) = m_i(t) + \alpha \cdot h_{c,i}(t)[x(t) - m_i(t)] \quad (7)$$

Donde  $t$  el tiempo discreto y número de iteración,  $\alpha$  es la tasa de aprendizaje y  $h_{c,i}$  es la función definiendo la vecindad. Muchas veces, los valores en la red  $m_i$  son inicializados aleatoriamente. La función de vecindad define la elasticidad de la red, así dependiendo de esta función se determina cuantas neuronas vecinas alrededor de la ganadora se mueven hacia ésta, cambiando la topología.

Este algoritmo se creó apropiado por la naturaleza de las señales y los latidos en cada paciente. Generalmente las señales de ECG tienen un gran

número de latidos normales, es decir de LoSV, que tiene por lo general un complejo QRS similar a los latidos arrítmicos supraventriculares, en cambio que las de origen ventricular, los latidos prematuros ventriculares y de fusión, contienen una forma de onda distinta. El gran número de LoSV se pueden asociar a neuronas que en cada iteración tendrán valores similares y podrán asociar más fácilmente este tipo de latidos, además que las neuronas vecinas podrán capturar latidos de origen supraventricular, pero con ciertas anomalías, por ejemplo, ruido. Las señales completamente diferentes se asociarán a neuronas distantes de las que están asociándose la mayoría.

Observando los datos de cada paciente, se puede notar que, en un paciente, el número de distintos tipos de forma de onda no es muy grande.

Por simple inspección se puede notar que por cada tipo de latido puede haber entre dos o tres formas distintas de onda en la mayoría de los casos.

Con esta información previa se realizaron pruebas con topologías de 4 y hasta 16 neuronas o grupos y esperando que uno estos diferentes grupos puedan separar los tipos de latidos correctamente.

El ACP es una técnica común para identificar patrones y reducir la dimensionalidad de la información con sus componentes de más alta variabilidad. El algoritmo presentado es una herramienta poderosa para poder graficar información de alta dimensiones en dos o tres dimensiones. Los

primeros componentes contienen la mayor variabilidad y va decreciendo conforme se avance a los siguientes componentes. De esta manera, el primero componente presenta la mayor variabilidad, el segundo componente presenta la segunda mayor variabilidad, y así sucesivamente.

El algoritmo es el siguiente:

La matrix de covarianza  $C$  es calculada como:

$$C = (X - \bar{x})(X - \bar{x})^T \quad (8)$$

Donde  $X$  es la matriz  $N \times d$  de información,  $N$  es el número total de muestras,  $d$  es el número de variables o características o dimensiones,  $\bar{x}$  representa la media de cada vector columna de  $X$ .

Los eigenvectores  $V$  y la matriz diagonal de eigenvalores  $D$  son calculados como:

$$D = VCV^{-1} \quad (9)$$

En base a los eigenvalores  $D$ , los eigenvectores son ordenados de manera descendente de acuerdo a los valores de eigenvalores  $V$ , y la información  $X$  es transformada tomando el producto entre la matriz de información y la matriz de eigenvectores ordenados para crear la representación en componentes principales  $Z$ :

$$Z = [V^T(X - \bar{x})]^T \quad (10)$$

La representación en dos dimensiones la información con las etiquetas de clase hechas por los médicos expertos y la de algoritmo separa claramente

los LoSV y los LoV. Así, cada señal es separada por el algoritmo en grupos o aglomerados para ser posteriormente descritos por una serie de descriptores con los que se analizará y evaluará que tipo de latido pertenece un aglomerado en específico.

### 5.3.3 Desarrollo de Descriptores

Para distinguir cuáles aglomerados pueden ser predominantemente LoSV y cuáles pueden ser de LoV, descriptores para cada aglomerado son calculados para caracterizarlos. Esta dicho que los latidos de origen ventricular aparecen prematuramente en comparación a la tendencia del ritmo cardiaco, esto quiere decir que el latido prematuro es un latido que aparece antes que los latidos normales. Con esta información previa, el ritmo cardiaco  $RR[N]$  es calculado. En la figura 13, se puede observar el intervalo R-R de un paciente. No todos los pacientes tienen un ritmo cardiaco estático, este cambia con respecto al tiempo y más en casos de arritmia. Un filtro tipo media móvil es aplicado para calcular la tendencia  $t[N]$  del ritmo cardiaco.

Un filtro no recursivo o filtro móvil promediado es comúnmente usado para eliminar ruido. La respuesta de este tipo del filtro es una suma ponderada de la misma señal. Se requiere una ventana que hacen la suma ponderada alrededor de la vecindad. Se utiliza la convolución para realizar este tipo de filtro, como se muestra:

$$y[n] = \sum_{k=0}^K w[k]x[n - k] \quad (11)$$

Aquí,  $k$  son los índices en términos de la ventana de la señal,  $w[k]$  representa la ventana de la señal,  $x[n - k]$  son los valores de la señal que serán filtradas y trasladados  $k$  términos, y  $y[n]$  es la señal filtrada. Para calcular la tendencia, la ventana contiene 13 términos, los pesos para el primer y último término son  $1/24$ ,  $1/12$  para los términos interiores.

Con el intervalo R-R en conjunto de la tendencia, la señal se divide en dos etiquetas, “latidos arriba de la tendencia” (LAT) y los demás como “latidos debajo de la tendencia” (LDT). La (Fig. 13) demuestra la etiqueta previamente dicho.

Otra de las suposiciones es que los LoSV y LoV están bien separados en el espacio de las características y que los de origen supraventricular se encuentran muy cercanos de sí mismos, formando grupos o un solo grupo dependiendo del paciente siendo un contraste con los de origen ventricular que pueden estar esparcidos en el espacio de las características. Para ver esto, se tiene que convertir la matriz  $X'(N \times s)$  que contiene cada latido en una matriz de características  $\Phi(N \times f)$ , donde  $f$  es la dimensión de las características.

Una de las maneras para crear otro espacio de características fue usar la transformada discreta wavelet, anteriormente explicada, usando las wavelets db6 y db3, una para el latido completo y otra para un intervalo de muestras entre la 60 a 170 que involucran prácticamente el complejo QRS de los latidos.

Otro conjunto de características es derivado de lo que denominamos, para facilitar la lectura, descriptores estadísticos (DE). Los DE están compuestos de la media aritmética, la desviación estándar, máximo, mínimo asimetría y la curtosis.

La media como descriptor de la tendencia central está definida como:

$$\bar{x} = \sum_{i=1}^N x[n_i] \quad (12)$$

La desviación estándar describe la dispersión de la información, y se calcula como:

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (x[n_i] - \bar{x})^2}{N}} \quad (13)$$

El rango es determinado por los valores máximo y mínimos de la información, respectivamente:

$$x_{max} = \max(x[n]) \quad (14)$$

$$x_{min} = \min(x[n]) \quad (15)$$

La asimetría y curtosis están en un área de la estadística que se denomina “Estadísticas de Orden Mayor”.

La asimetría es la tasa del tercer momento y de segundo momento a la potencia de 3/2, como se muestra a continuación:

$$Sx_j = \frac{1}{N} \frac{m_3x}{(m_2x)^{3/2}} \quad (16)$$

Donde:

$$m_3x = \frac{\sum_{i=1}^N (x[n_i] - \bar{x})^3}{N} \quad (17)$$

$$(m_2x)^{3/2} = \sigma_j^3 \quad (18)$$

La curtosis es la tasa entre el cuarto momento y el segundo momento al cuadrado. El menos 3 se define como una corrección que se hace a la curtosis para la distribución normal, ya que la curtosis de la distribución gaussiana es de 3.

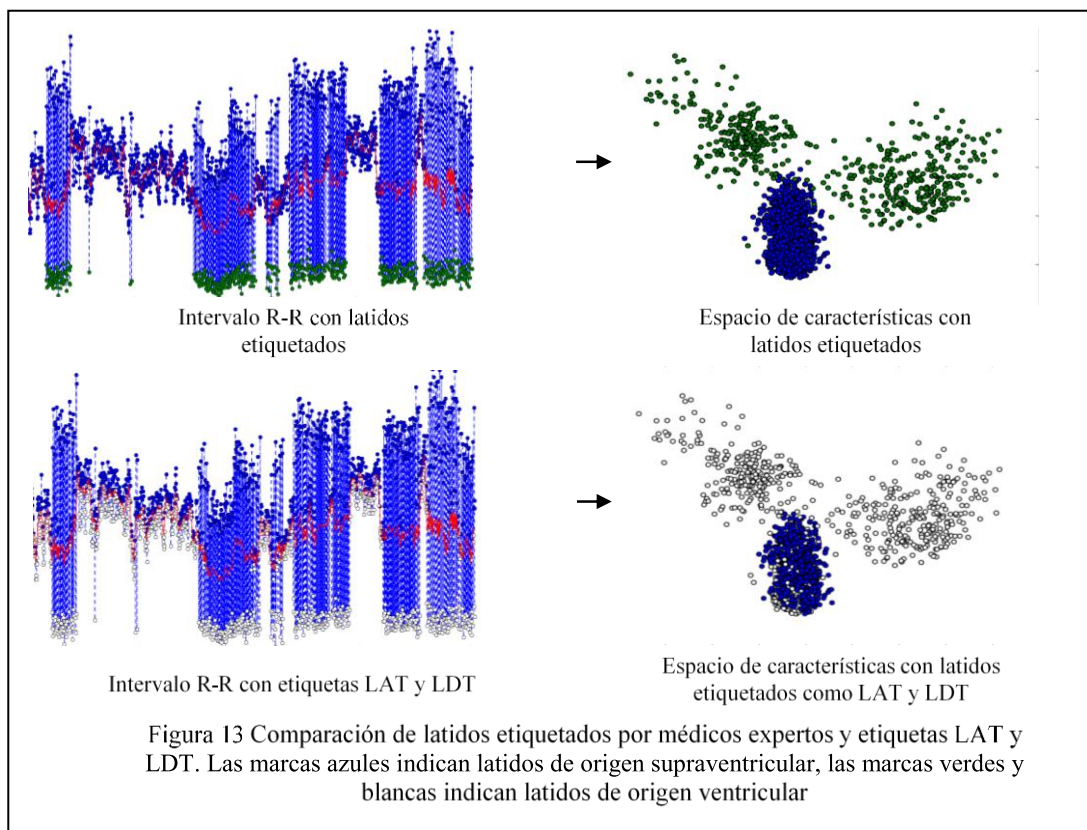
$$Kx_j = \frac{1}{N} \frac{m_4x}{(m_2x)^2} - 3 \quad (19)$$

donde:

$$m_4x = \frac{\sum_{i=1}^N (x[n_i] - \bar{x})^4}{N} \quad (20)$$

$$m_2x = \sigma^2 \quad (21)$$

Existen muchas otras propuestas por muchos otros trabajos [13-32] pero uno de los fines de esta propuesta es usar características que no sean exhaustivas o impliquen transformaciones complicadas. Aunque



características importantes como la duración del complejo QRS (por medio del algoritmo de Pan-Tompkins) y el intervalo R-R son ampliamente usadas, cuando se hicieron las pruebas preliminares incluyendo estas características los porcentajes de clasificación no cambiaban o solían ser peores, por lo que no se incluyeron en la experimentación.

La figura 13 muestra tanto en el ritmo cardiaco como en espacio de las características, que la suposición de que la mayoría de los latidos arriba de la tendencia son normales. Con la ayuda de los LAT y el algoritmo de Maquinas de Soporte Vectorial de Una-Clase (MSVUC), un número parcial de los latidos de origen supraventricular son identificados. El algoritmo MSVUC es un algoritmo de detección de novedad, lo cual quiere decir que solo entrena con información positiva o verdadera. Aprende funciones de decisión para clasificar entradas dentro o fuera de los datos de entrenamiento.

El algoritmo original de Maquina de Soporte Vectorial (MSV) de dos clases se cambia para trabajar una sola clase. Básicamente, una vez que el truco de kernel se haya hecho y la información se haya transformado, ciertas muestras son tratadas como una segunda clase. Usando hiperparámetros, el número de muestras de la segunda clase es modificada en términos de que esta puede incrementar o decrecer, y el resto de las muestras puede ser separada por una función de decisión por procedimientos estándar de MSV, donde la primera clase es tratada como información verdadera o positiva.

Si la información tiene una distribución de probabilidad  $P$ , después de transformar la información con el truco kernel, la tarea es encontrar un subconjunto  $S$  de ésta información que algunas muestras de la distribución  $P$  se encuentren fuera de  $S$  por medio de un valor especificado  $\nu \in (0,1)$ . La solución a este problema es estimar una función la cual es positiva dentro del subconjunto  $S$ , reteniendo la gran parte de la información positiva, y negativo fuera del subconjunto o  $\bar{S}$ . La función  $f$  puede ser vista como:

$$f(x) = \begin{cases} +1 & \text{if } x \in S \\ -1 & \text{if } x \in \bar{S} \end{cases} \quad (22)$$

Donde  $x_1, x_2, \dots, x_N$  son muestras de entrenamiento para una clase  $X$ .

Entonces, para separar la información en la segunda clase, es necesario crear una función de decisión la cual se resuelve el siguiente problema cuadrático:

$$\min \frac{1}{2} \|w\|^2 + \frac{1}{\nu N} \sum_{i=1}^N \xi_i - \rho \quad (23)$$

Sujeto a:

$$(w \cdot \Phi(x_i)) \geq \rho - \xi_i \quad (24)$$

$$i = 1, 2, \dots, N$$

$$\xi_i \geq 0$$

Donde  $\Phi: X \rightarrow H$  sea el mapeado kernel que transforma la información en otro espacio,  $N$  es el número máximo de muestras de entrenamiento,  $w$  y  $\rho$  son vectores de pesos y "offset" parametrizado del hiperplano en el espacio

de las características, y  $\xi_i$  la variable “slack” de las MSV estándar para prevenir sobreajuste.

Resolviendo el problema cuadrático anterior, la función de decisión es:

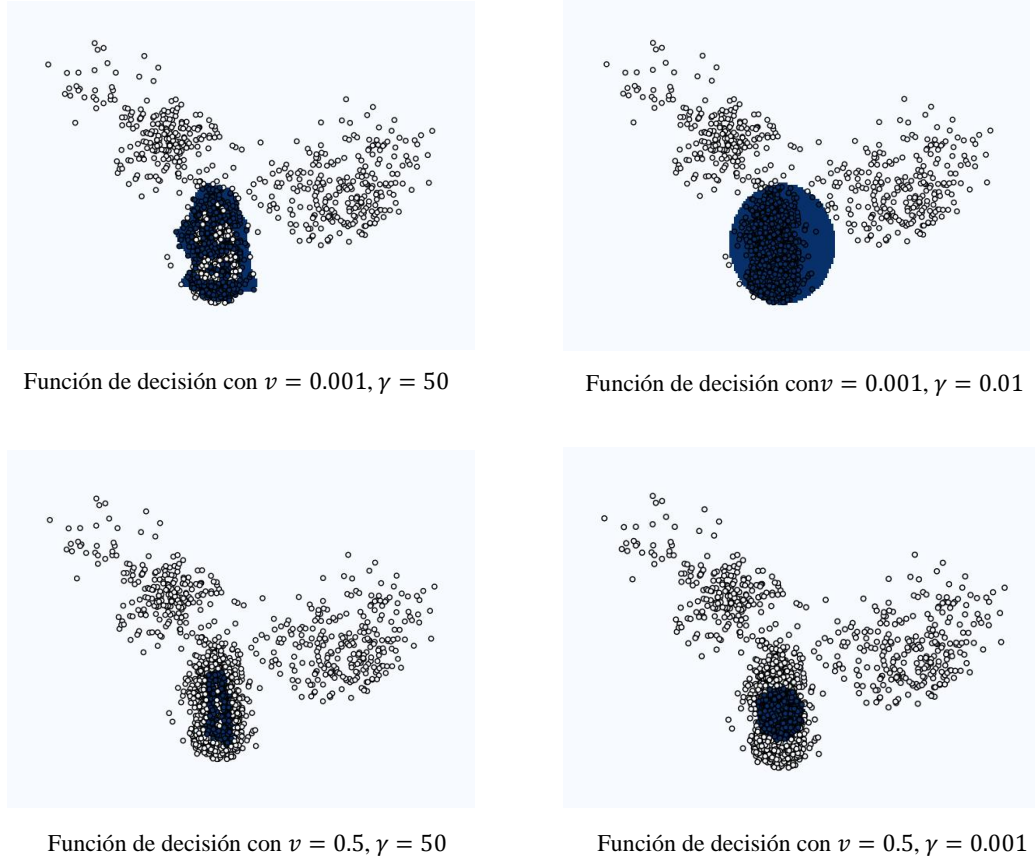
$$f(x) = \text{sign}[(w \cdot \Phi(x_i)) - \rho] \quad (25)$$

Y la mayoría de las muestras  $x_i$  contenidas en el entrenamiento estarán dentro de la función de decisión y serán consideradas positivas o verdaderas.

El kernel usado para este trabajo fue el de Función de Bases Radiales (FBR), comúnmente usado para aplicaciones no lineales y se muestra como:

$$\Phi(x_i) = \exp(-\gamma \|x_i - x\|^2), \gamma > 0 \quad (26)$$

El algoritmo MSVUC es conveniente en este caso, ya que queremos determinar el mayor número de latidos de origen supraventricular posible. Para se usara como información verdadera o positiva los LAT con sus



**Figura 14** Ilustración de las diferentes funciones de decisión cambiando los hiperparámetros en el algoritmo de MSVUC

respectivas representación en el espacio de las características. En la figura 14 se puede apreciar cuales muestras se utilizarán como verdaderas y el objetivo es determinar las faltantes. Cambiando el valor del hiperparámetro  $v$  la función de decisión cambia, así mismo, como en este trabajo se utilizó el kernel FBR, el parámetro  $\gamma$  contribuye en modificar la función de decisión.

En la figura 14 se puede observar diferentes valores de estos hiperparámetros y cómo afectan la función de decisión en la señal. Unos valores óptimos de hiperparámetros captarán la mayoría de las señales de origen supraventricular. Los latidos clasificados como origen supraventricular servirán igual como descriptores de cada aglomerado, así como los LAT y LDT.

### 5.3.4 Proporciones y etiquetado de clase

En la Tabla I se muestra un ejemplo de una señal separada en aglomerado con el número de latidos asociados a cada grupo, así como sus descriptores el número de LAT, LDT y LoSV asociados en cada aglomerado.

TABLA I  
EJEMPLO DE SEÑAL ECG EN AGLOMERADOS Y SUS DESCRIPTORES

Aglomerado ( $cl_j$ )	# Latidos en $cl_j$	# LAT en $cl_j$	# LDT en $cl_j$	# LoSV
1	227	0	227	0
2	292	195	97	273
3	346	216	130	221
4	478	316	162	385
5	451	299	152	394
6	229	0	229	0

Para determinar si un aglomerado  $cl^j$  pertenece a latidos de origen supraventricular o de origen ventricular, tres proporciones  $P_i^{cl_j}$ , donde  $i = \{1,2,3\}$  y  $cl_j$  es el aglomerado  $j$ , son calculados usando los descriptores previamente definidos.

Cada proporción  $P_i^{cl_j}$  es comparado con sus correspondientes umbrales  $d_i$  y los resultados de la comparación son usados para clasificar el aglomerado  $cl_j$  en LoSV o de LoV.

La primera proporción  $P_1^{cl_j}$  es calculada como:

$$P_1^{cl_j} = \frac{\# \text{ LoSV en } cl_j}{\# \text{ LDT en } cl_j} \quad (27)$$

Esta proporción es el porcentaje de latidos de origen supraventricular identificados en el aglomerado  $cl_j$ . Aglomerados un con gran número de LoSV tendrán un porcentaje muy alto. Si la proporción sobrepasa el umbral  $d_1$ , entonces el aglomerado  $cl_j$  etiquetado como latidos de origen supraventricular.

La segunda proporción  $P_2^{cl_j}$  es:

$$P_2^{cl_j} = \frac{\# \text{ LoSV}}{\# \text{ of BTB in } cl_j} \quad (28)$$

Esta proporción representa el error del etiquetado del algoritmo MSVUC y el de aglomerar LoSV en donde la mayoría es de origen ventricular. Se espera que en aglomerados que no contienen solamente LDT y ninguno LAT sean de origen ventricular. Desafortunadamente, algunos latidos de origen supraventricular pueden estar mezclados con latidos de origen ventricular y el algoritmo MSVUC los identificase como origen supraventricular. En esos casos, comparar el número de LoSV con el número total de LDT puede describir el aglomerado. Si el umbral  $d_2$  es sobrepasado,

entonces el aglomerado es identificado como LoSV. Para tener grandes valores en esta proporción, es necesario un gran número de LoV en comparación a los LDT. Si el aglomerado no contiene ningún LDT, entonces la proporción no es calculada.

Por último, la proporción  $P_3^{cl_j}$  es calculada como:

$$P_3^{cl_j} = \frac{\# \text{LAT en } cl_j}{\# \text{Latidos en } cl_j} \quad (29)$$

Finalmente, como se ha dicho anteriormente, la suposición de que la mayoría de los latidos de origen supraventricular son LAT. Entonces si existe un gran número de LAT en comparación con los latidos en este aglomerado, el valor de la proporción será grande y podrá sobrepasar el umbral  $d_3$ , clasificando el aglomerado como LoSV.

La regla de clasificación es que si alguno de estas proporciones es superada, entonces el aglomerado es etiquetado como latido de origen supraventricular, de otra manera será de origen ventricular.

## 5.4 Experimentación

Esta aproximación tiene un gran número de hiperparámetros que cambiando sus valores puede modificar el resultado.

Los parámetros MAK son: a) topología de la red, número de neuronas, número de vecinos, la tasa de aprendizaje y numero de iteraciones. Un MAK es un algoritmo de aglomerado y no determinístico, entonces consideramos

la reproducibilidad como un factor importante para obtener resultados similares cada vez que el algoritmo se implemente y que no sean resultados optimistas de una sola ocasión, sino que no exista mucha variabilidad entre estos y se pueda usar sin problema en futuras señales.

El algoritmo MSVUC tiene el parámetro  $\nu$ , el cual determina una proporción de latido a fuera de la función de decisión. El kernel seleccionado para este trabajo es el FBR, y tiene un parámetro  $\gamma$ , que dependiendo de su valor también puede cambiar significativamente la función de decisión. Finalmente, los umbrales  $d_i$  para determinar si un aglomerado es un de origen supraventricular o de origen ventricular necesitan ser determinados también. Adicionalmente, se hacen pruebas con diferentes conjuntos de características extraídas.

En este trabajo, algunos valores parámetros fueron determinados experimentalmente, mientras otros fueron seleccionados por defecto porque el costo computacional es alto. Hiperparámetros seleccionados por defecto para MAK: tamaño de la vecindad son tres, la red de la topología es hexagonal con 200 iteraciones de entrenamiento, y el kernel utilizado para el algoritmo MSVUC fue el FBR. Además, las muestras entre la 60 a 170 fueron de la matriz  $X(N \times s)$  son utilizadas en algoritmos aglomerados porque incluye el complejo QRS, la mayor diferencia entre LoSV y LoV. Los parámetros que se determinaron experimentalmente fueron: la dimensión de la red, el  $\nu$  del algoritmo MSVUC,  $\gamma$  para el kernel de FBR, y los umbrales  $d_i$ .

Las características que utilizamos son de dos tipos, la primera es del dominio de tiempo, incluye media, desviación estándar, máximo, mínimo, asimetría y curtosis, que por conveniencia nos referiremos a esto como “características estadísticas” (CE). El segundo tipo que incluimos son los coeficientes de la transformada discreta wavelet. Tres aproximaciones son usadas para calcular estas características. En una, cada latido de la matriz  $X(N \times s)$  es dividido en tres partes: antes, después y dentro del complejo QRS.

La segunda utiliza el complejo QRS para calcular las características, y el tercero utiliza el latido completo. La tabla 3 muestra las diferentes características calculadas. Las características básicas son: subconjunto 1 es la transformada discreta wavelet “db3” del complejo QRS, subconjunto 2 es la transformada discreta wavelet “db6” del latido completo, subconjunto 3 es el latido separado en secciones (antes, después y en el complejo QRS) y CE son calculadas, el subconjunto 4 es calcular las CE del complejo QRS.

Entonces, cada conjunto de características es formado utilizando uno o más de estos subconjuntos básicos: el conjunto 1 es el subconjunto 1 y transformado utilizando ACP, el conjunto 2 es el subconjunto 2 transformándolo utilizando ACP, el conjunto 3 es la concatenación del subconjunto 1 y subconjunto 4, y convertidos en el espacio de componentes principales por ACP, el conjunto 4 es simplemente el subconjunto 4, el conjunto 5 es el subconjunto 3 transformado utilizando ACP, el conjunto 6 es

la concatenación de los subconjuntos 1 y 3, siguiendo una transformación por medio del algoritmo ACP, y el conjunto 7 es la concatenación de los subconjuntos 2 y 4, y la transformación usando ACP. La tabla 2 resume las características básicas y los conjuntos de características creados a partir de estos.

Primero, 5 tipos de topologías en el MAK son utilizados para determinar cuál es más apropiado a las señales de ECG de cada paciente: 2x2, 3x2, 3x3, 4x3, and 4x4.

Por cada tipo de MAK se corrieron 5 veces y se probaron con un conjunto de hiperparámetros ( $\nu = 0.1$ ,  $\gamma = 1.5$ ,  $d_1 = 0.5$ ,  $d_2 = 0.7$ , y  $d_3 = 0.3$ ) y como parámetros por defecto fue el conjunto de características 1 para determinar la reproducibilidad de los resultados en cada topología. Los valores de los parámetros y características fueron seleccionados porque se obtuvieron buenos resultados en los primeros experimentos. Experimentando con estas variables por defecto, proporciona una percepción de la correcta topología a usar. Una vez la topología es seleccionada, los conjuntos de características y los hiperparámetros son determinados utilizando tres diferentes valores de hiperparámetros en cada conjunto de característica por cada base de datos. Las tres mejores características son seleccionadas y entonces se experimentan con otros 5 diferentes valores de hiperparámetros y el mejor es el seleccionado para mostrar y comparar resultados.

Por el gran desbalance entre clases, es recurrente presentar resultados en términos de sensibilidad ( $S$ ) y valor predictivo positivo ( $P^+$ ), como se

presenta en [26]. Adicionalmente, el F-score es presentado ya que es un término de que relaciona el balance entre  $S$  y  $P^+$ . El F-score es calculado como:

$$F = 2 \frac{S * P^+}{(S + P^+)} \quad (30)$$

El F-score puede ser visto como una medida global del rendimiento. Con valores entre cero y la unidad, el mejor performance puede es de 1, necesitando que  $S$  y  $P^+$  sean valores altos para tener un resultado alto en el F-score. Si algunos de las dos medidas de performance es bajo, el F-score cae abruptamente, por eso este medida se llama media armónica.

En esta propuesta buscamos extensivamente la mejor topología de MAK, el conjunto de características e hiperparámetros posible, dando como resultado un gran número de resultados para  $S$ ,  $P^+$ , y  $F$ . Cambiando los valores de los hiperparámetros y los conjuntos de características, los resultados varían para cada base de datos ya que puede incrementarse o decrementarse. El propósito de este conjunto de experimentos es determinar valores de hiperparámetros y el conjunto de características que tengan el mejor balance posible entre los resultados finales de cada base de datos. Para obtener esto, una breve modificación se realiza a la fórmula de F-score para poder obtener un F-general de acuerdo a los F-scores de cada base de datos, como se ve en la ecuación siguiente:

$$Fg = 3 \frac{F_{SUPRA} * F_{MITBIH} * F_{INCART}}{(F_{SUPRA} + F_{MITBIH} + F_{INCART})} \quad (31)$$

El comportamiento de esta fórmula es la misma que el F-score, simplemente esta modificada para poder ser usada con tres variables. Es la media armónica entre los tres valores de F-score de las bases de datos a experimentar. La razón que usemos esta medida es para evitar obtener hiperparámetros y conjuntos de características que beneficien más a una sola base de datos que otras. Es posible esto ya que cada base de datos contiene pacientes con diferentes patologías, el número de tipo de latidos varía grandemente y la dificultad para detectarlos puede variar en caso de presentar señales muy complicadas. Ésta fórmula es aplicada para seleccionar el tipo de MAK, los hiperparámetros y el conjunto de características.

## 6. RESULTADOS

Similarmente en [52,53], los resultados son por cada base de datos. En la (Tabla II), cada señal de cada paciente es aglomerada 5 veces por cada tipo de topología presentada en este trabajo, y el algoritmo propuesto fue implementado con los hiperparámetros y conjunto de características por defecto antes mencionadas.

Esto se hizo para asegurar la reproducibilidad de los resultados, en términos de  $S$  y  $P^+$ . La media y desviación estándar fueron tomados por cada 5 corridas por cada base de datos en cada tipo de topología. La desviación estándar no varía prácticamente, teniendo valores de centésimas, lo que significa que no existen o existen cambios no significativos entre los resultados dentro de cada topología. Además de esto, este experimento sirve para detectar cual topología MAK puede ser tomada para los futuros experimentos. Para esto, se hace uso del F-general antes mencionado utilizando los F-scores de cada resultado de topología en cada base de datos en términos de los latidos de origen ventricular, ya que los latidos de origen supraventricular tienen un porcentaje muy cercano al 100%. Comparando el F-general, se mira claramente en la (Tabla III) que la topología 3x2 mantiene el mejor balance entre los resultados F-score de las tres bases de datos, siendo esta la usada en los próximos experimentos.

TABLA II  
RESULTADOS DEL EXPERIMENTO DE REPRODUCIBILIDAD DE MAK

logia	MAK Topo	VBo		SVBo		VBo		F score
		S	P+	S	P+	P+	F	
PRA	SU	0.8	0.78	0.9	0.9	0.9	0.8	
		5905	189	8632	9191	1866		
		0.0	0.00	0.0	0.0	0.0	0.0	
		0020	052	0004	0001	0030		
		0.8	0.79	0.9	0.9	0.9	0.8	
		9814	383	8654	9115	4277		
	3x2	0.0	0.00	0.0	0.0	0.0	0.0	
		0216	071	0019	0407	0109		
		0.8	0.77	0.9	0.9	0.9	0.8	
		9386	637	8530	9389	3095		
		0.0	0.00	0.0	0.0	0.0	0.0	
		0460	717	0067	0026	0299		
	4x3	0.8	0.79	0.9	0.9	0.9	0.7	
		7991	268	8368	9083	9090		
		0.0	0.09	0.0	0.0	0.0	0.0	
		3701	298	0667	0414	0551		
0.9		0.68	0.9	0.9	0.9	0.7		
0934		555	7617	9473	8168			
4x4	0.0	0.01	0.0	0.0	0.0	0.0		
	0798	400	0152	0046	1005			
	0.8	0.94	0.9	0.9	0.9	0.8		
	0750	047	9576	8423	6893			
	0.0	0.00	0.0	0.0	0.0	0.0		
	0027	013	0001	0002	0021			
BIH	3x2	0.8	0.91	0.9	0.9	0.9	0.8	
		3549	752	9377	8600	7458		
		0.0	0.00	0.0	0.0	0.0	0.0	
		0108	310	0026	0100	0116		
		0.8	0.88	0.9	0.9	0.9	0.8	
		4905	435	9078	8753	6631		
	3x3	0.0	0.00	0.0	0.0	0.0	0.0	
		0207	994	0092	0016	0378		
		0.8	0.84	0.9	0.9	0.9	0.8	
		5440	955	8738	8792	5177		
		0.0	0.02	0.0	0.0	0.0	0.0	
		0229	786	0273	0018	1351		
4x4	0.8	0.85	0.9	0.9	0.9	0.8		
	6079	686	8807	8845	5879			
	0.0	0.01	0.0	0.0	0.0	0.0		
	0230	002	0100	0018	0436			
	0.8	0.94	0.9	0.9	0.9	0.9		
	9461	787	9360	8640	2047			
ART	2x2	0.0	0.00	0.0	0.0	0.0	0.0	
		0119	050	0006	0015	0071		
		0.9	0.91	0.9	0.9	0.9	0.9	
		2128	843	8936	8976	1985		
		0.0	0.00	0.0	0.0	0.0	0.0	
		0178	336	0048	0023	0188		
	3x3	0.9	0.88	0.9	0.9	0.9	0.9	
		2325	574	8452	8997	0410		
		0.0	0.00	0.0	0.0	0.0	0.0	
		0231	296	0043	0030	0231		
		0.9	0.86	0.9	0.9	0.9	0.8	
		2732	486	8116	9046	9498		
4x3	0.0	0.00	0.0	0.0	0.0	0.0		
	0226	752	0122	0029	0381			
	0.9	0.87	0.9	0.9	0.9	0.8		
	2359	453	8277	9000	9839			
	0.0	0.00	0.0	0.0	0.0	0.0		
	0042	249	0039	0005	0129			

Como los parámetros por defecto usados dieron buenos resultados en las primeras pruebas, otros valores de hiperparámetros extremos en comparación a los de defecto se pusieron a prueba con los 7 conjuntos de características presentadas anteriormente. Los valores a prueba por cada hiperparámetros son:  $v = \{0.001, 0.1, 0.5\}$ ,  $\gamma = \{0.01, 1.5, 3\}$ ,  $d_1 = \{0.4, 0.5, 0.6\}$ ,  $d_2 = \{0.5, 0.6, 0.7\}$ , and  $d_3 = \{0.2, 0.3, 0.4\}$ .

TABLA III  
SELECCIÓN DE TOPOLOGÍA MAK

	SUPRA	MITBIH	INCART	F-general
2x2	0.81866	0.86893	0.92047	0.75318503
<b>3x2</b>	<b>0.84277</b>	<b>0.87458</b>	<b>0.91985</b>	<b>0.77126533</b>
3x3	0.83095	0.86631	0.9041	0.75056012
4x3	0.7909	0.85177	0.89498	0.71276568
4x4	0.78168	0.85879	0.89839	0.71262883

En total cada hiperparámetro tiene 3 valores diferentes, dando por resultado 243 experimentos por cada conjunto de características por cada base de datos. En cada experimentación el  $S$ ,  $P^+$ , and  $F_s$  fueron calculados y solamente los mejores F-scores por cada conjunto de características por cada base de datos son presentado en la (Tabla IV).

TABLA IV  
SELECCIONAR LAS MEJORES TRES CARACTERÍSTICAS

	SUPR A	MITBI H	INCAR T	F-general
<b>Conjunto 1</b>	<b>0.8892</b>	<b>0.8755</b>	<b>0.9214</b>	<b>0.8011298</b>
Conjunto 2	0.8602	0.8755	0.9280	0.7871173
<b>Conjunto 3</b>	<b>0.8892</b>	<b>0.8755</b>	<b>0.9214</b>	<b>0.8011298</b>
<b>Conjunto 4</b>	<b>0.8957</b>	<b>0.8723</b>	<b>0.9468</b>	<b>0.8174667</b>
Conjunto 5	0.8946	0.8721	0.8687	0.7715067
Conjunto 6	0.8184	0.7725	0.9029	0.6866942
	0	0	0	23
	0	0	0	26

<i>Conjunto</i>	0.8608	0.8721	0.8919	0.7652612
7	0	0	0	91

Los mejores hiperparámetros por cada conjunto son: *Conjunto 1* =  $\{v = 0.1, \gamma = 1.5, d_1 = 0.4, d_2 = 0.5, \text{ and } d_3 = 0.3\}$ , *Conjunto 2* =  $\{v = 0.001, \gamma = 3, d_1 = 0.6, d_2 = 0.7, \text{ and } d_3 = 0.3\}$ , *Conjunto 3* =  $\{v = 0.1, \gamma = 1.5, d_1 = 0.4, d_2 = 0.5, \text{ and } d_3 = 0.3\}$ , *Conjunto 4* =  $\{v = 0.1, \gamma = 1.5, d_1 = 0.4, d_2 = 0.6, \text{ and } d_3 = 0.3\}$ , *Conjunto 5* =  $\{v = 0.1, \gamma = 0.01, d_1 = 0.6, d_2 = 0.6, \text{ and } d_3 = 0.4\}$ , *Conjunto 6* =  $\{v = 0.001, \gamma = 3, d_1 = 0.5, d_2 = 0.6, \text{ and } d_3 = 0.3\}$ , *Conjunto 7* =  $\{v = 0.1, \gamma = 0.01, d_1 = 0.6, d_2 = 0.7, \text{ and } d_3 = 0.3\}$ .

El F-general es calculado por cada F-score de cada base de datos por cada conjunto de características. Los tres mejores fueron seleccionados para hacer más pruebas y otro rango de valores de hiperparámetros. Es importante mencionar que los tres mejores fueron los conjuntos 1,3 y 4, y estos son los que utilizan el complejo QRS, lo cual, es muy acertado ya que en el campo médico es una forma de onda distintiva entre latidos de origen supraventricular y de origen ventricular.

Con los hiperparámetros de los tres conjuntos antes seleccionados son prácticamente los mismos, solo variando el  $d_2 = 0.6$  para el conjunto 4 en

comparación de  $d_2 = 0.5$  en los conjuntos 1 y 3, los otros valores con los que se experimentaron fueron:  $v = \{0.05, 0.1, 0.15, 0.25, 0.3\}$ ,  $\gamma = \{1, 1.25, 1.5, 2, 2.25\}$ ,  $d_1 = \{0.3, 0.35, 0.4, 0.45, 0.5\}$ ,  $d_2 = \{0.55, 0.575, 0.6, 0.625, 0.65\}$ , y  $d_3 = \{0.25, 0.275, 0.3, 0.325, 0.35\}$ . Con esto, el número de experimento se incrementa a 3125 por cada base de datos por cada conjunto de características.

El procedimiento para seleccionar el mejor conjunto de características e hiperparámetros relacionado es el mismo. Las medidas del rendimiento o “performance”  $S$ ,  $P^+$ , y  $F_s$  fueron calculados y solamente los mejores F-scores de los tres conjuntos de características por cada base de datos son presentados en la (Tabla V).

TABLA V  
SELECCIONAR LOS MEJORES CONJUNTOS DE CARACTERÍSTICAS

	SUPRA	MITBI H	INCA RT	F-general
<i>Conjunto 1</i>	0.9005	0.865 50	0.9276 0	0.805192 43
<i>Conjunto 3</i>	0.8892	0.886 20	0.9187 0	0.806143 69
<b>Conjunto 4</b>	<b>0.895693</b> <b>57</b>	<b>0.886</b> <b>20</b>	<b>0.9394</b> <b>0</b>	<b>0.822029</b> <b>9</b>

Nuevamente el F-general a partir de los F-score de los latidos de origen ventricular son calculados. En esta ocasión, los hiperparámetros para cada conjunto fueron diferentes: *Conjunto 1* =  $\{v = 0.05, \gamma = 2.25, d_1 = 0.45, d_2 = 0.55, \text{ and } d_3 = 0.35\}$ , *Conjunto 3* =  $\{v = 0.1, \gamma = 1.25, d_1 = 0.3, d_2 = 0.55, \text{ y } d_3 = 0.3\}$ , *Conjunto 4* =  $\{v = 0.15, \gamma = 1, d_1 =$

$0.35$ ,  $d_2 = 0.55$ , and  $d_3 = 0.3$ }. Aunque en la prueba anterior prácticamente eran los mismos valores, en esta prueba terminaron con valores completamente diferentes para cada conjunto de características.

Existe una pequeña mejora en el F-general comparada con los valores obtenido en la (Tabla IV). El mejor conjunto de características se muestra en la (Tabla V) con el conjunto 4 con un F-general de  $0.8220$ , con esto, la experimentación termina con una topología MAK de  $3 \times 2$ , utilizando el conjunto de características 4 y los hiperparámetros de  $\nu = 0.15$ ,  $\gamma = 1$ ,  $d_1 = 0.35$ ,  $d_2 = 0.55$ , y  $d_3 = 0.3$ . Otro punto relevante, es que el conjunto de características seleccionadas son operaciones estadísticas sencillas de implementar al contrario de una cascada de filtros que se necesita para la transformada discreta wavelet u otro tipo de transformadas ya sea lineales o no lineales o características de búsqueda exhaustiva en la forma de onda.

Los resultados de todas las bases de datos en comparación con trabajos similares se presentan en la (Tabla VI). Además, el algoritmo también fue probado en dos bases de datos derivadas del MITBIH como se hace en [53] y [54]. Adicionalmente, en la (Fig. 15) se presenta un histograma con los pacientes que tienen como mínimo 40 latidos de origen ventricular y sus porcentajes de F-score. Aunque el médico tiene la última palabra y decide cuantos latidos de origen ventricular son significativos en toda la señal de ECG, nosotros notamos que nuestro algoritmo trabajo mejor cuando se tiene cuando menos 40 latidos de origen ventricular y la explicación es que el

algoritmo de aglomerado necesita una muestra mínima para poder asociar correctamente los tipos de latidos presentes en la señal.

TABLA VI  
COMOPARATIVA DE RESULTADOS CON TRABAJOS SIMILARES

Tipo de modelo	Base de datos	Trabajo	Latidos normales		Latidos Supraventriculares		LoSV		LoV		F-score de LoV	
			S	P <sup>+</sup>	S	P <sup>+</sup>	S	P <sup>+</sup>	S	P <sup>+</sup>		
Modelos generales	MITBIH-AR DS2	Mar[31]	0.90	0.99	0.83	0.34	0.87	0.61	0.87	0.61	0.7171	
		Chazal[28]	87	99	0.759	0.385	0.777	0.819	0.777	0.819	0.7974	
		Llamedo[28]			0.77	0.39	0.81	0.87	0.81	0.87	0.8389	
		Ye[30]			0.608	0.523	0.815	0.631	0.815	0.631	0.7112	
		<b>Este trabajo</b>						<b>0.9996</b>	<b>0.9848</b>	<b>0.8039</b>	<b>0.9945</b>	<b>0.8891</b>
	MITBIH-AR DS2	Llamedo[53]	0.93 ±0	0.99±0	0.77±0	0.39±0	0.82±0	0.70±0	0.82±0	0.70±0	0.7552	
	MITBIH-AR	<b>Este trabajo</b>					<b>0.9996</b>	<b>0.9848</b>	<b>0.8039</b>	<b>0.9945</b>	<b>0.8891</b>	
	MITBIH-AR common tests records	AI Rahhal[54]			0.115	0.132	0.847	0.871	0.847	0.871	0.8588	
		<b>Este trabajo</b>					<b>0.9928</b>	<b>0.9797</b>	<b>0.8309</b>	<b>0.9335</b>	<b>0.8792</b>	
Modelos adaptativos al paciente	MITBIH	Llamedo[53]	0.96±0	0.98±0	0.76±2	0.43±2	0.80±2	0.82±3	0.80±2	0.82±3	0.8098	
		AI Rahhal[54]			0.41	0.429	0.91	0.795	0.91	0.795	0.8486	
		HAMILTON[32]					0.928	0.795	0.928	0.795	0.8563	
		<b>Este trabajo</b>					<b>0.9957</b>	<b>0.9865</b>	<b>0.8360</b>	<b>0.9428</b>	<b>0.8862</b>	
	SUPRA	Llamedo[53]	0.94±0	0.97±0	0.47±3	0.50±1	0.82±0	0.54±1	0.82±0	0.54±1	0.6511	
		AI Rahhal[54]			0.880	0.1431	0.6519	0.931	0.6519	0.931	0.1639	
		<b>Este trabajo</b>					<b>0.9938</b>	<b>0.9941</b>	<b>0.8981</b>	<b>0.8930</b>	<b>0.8956</b>	
	INCART	Llamedo[53]	0.89±0	0.99±0	0.74±4	0.8±0	0.88±0	0.96±1	0.88±0	0.96±1	0.9182	
		AI Rahhal[54]			0.1558	0.0254	0.7511	0.3763	0.7511	0.3763	0.5013	
		<b>Este trabajo</b>					<b>0.9946</b>	<b>0.9899</b>	<b>0.9220</b>	<b>0.9575</b>	<b>0.9394</b>	

## 7. DISCUSIÓN

Los resultados finales son presentados en la (Tabla VI) comparando los resultados de otros trabajos donde no presentan entrenamiento con el mismo paciente, excepto para la base de datos del MITIBH ya que todos entrenan con un número de pacientes de esta base de datos y prueban con la base de datos completa.

Una de las mayores diferencias entre todos los trabajos es el porcentaje de  $P^+$  en los latidos de origen ventricular, donde alguna el algoritmo propuesto presenta valores arriba del 90% con la única excepción de la base de datos SUPRA con un muy cercano 0.8930%. Esto quiere decir que el gran número de latidos clasificados como latidos de origen ventricular son clasificados correctamente. Este porcentaje marca la diferencias en la base de datos del MITBIH y las derivadas de ésta, las cuales son MITBIH-AR DS2 and MITBIH-AR pruebas comunes, donde se tienen un  $P^+$  de 0.9428, 0.9945 and 0.9335, respectivamente, y están arriba de los trabajos similares. El  $S$  de trabajos previos en MITBIH es un poco más alta que el de esta propuesta, sin embargo, tenemos un valor alrededor del 80%, está a unas cuantas unidades porcentuales de los otros autores.

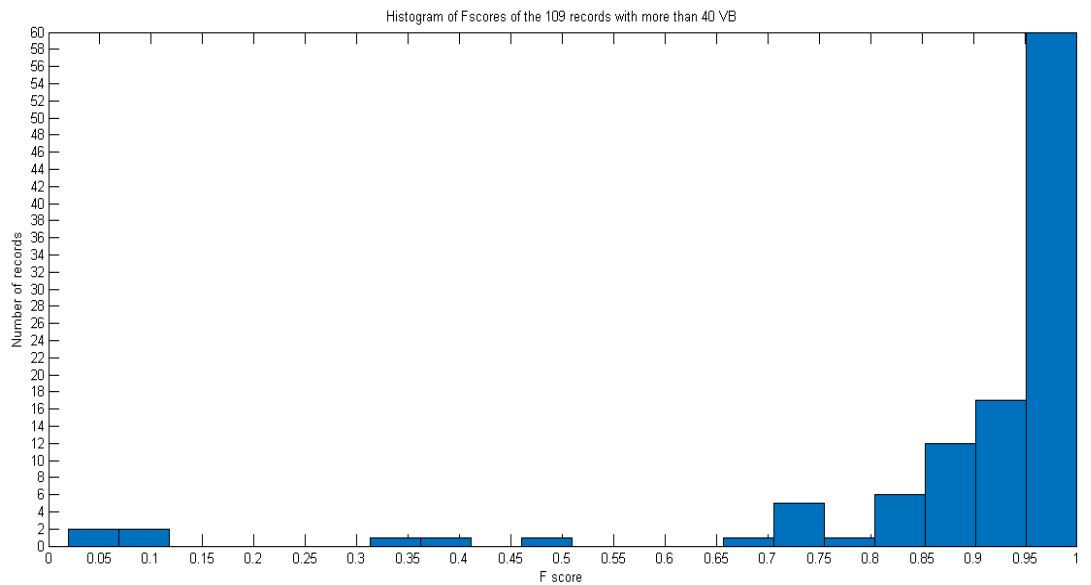
El F-score juega un papel importante para evaluar los resultados entre las bases de datos de este y otros trabajos. La métrica revela la media armónica, y puede utilizarse para comparar un valor único entre los trabajos.

Anteriormente se había dicho que si un valor, ya sea la sensibilidad o valor positivo predictivo, son bajos el F-score tiene una caída más abrupta que la media aritmética. En los modelos generales, esto pasa en los casos de Mar *et al.* [31] y Ye *et al.* [30] donde ellos presentan un  $P^+$  cerca de 0.60, hundiendo el F-score. Mientras que Chazal *et al.* [28] y Llamedo *et al.* [29] mantienen valores de resultados similares en ambos  $S$  y  $P^+$  pero la propuesta presenta mejores resultados en F-score ya que  $P^+$  mucho más alto que los otros trabajos.

En otros trabajos, ellos presentan un modelo que se puede adaptar al paciente. Nosotros comparamos nuestra propuesta con estos trabajos donde presentan resultados sin incluir información del mismo paciente, de otra manera serían cerca del 95%. Solamente Llamedo *et al.* [53] y Al Rahhal *et al.* [54] presentan este tipo de resultados, con la excepción de que entrenan con un número de pacientes de la base de datos del MITBIH y prueba con toda la base de datos. La propuesta en este trabajo presenta mejores resultados que los de otros trabajos en comparación de los LoV, ya que nuestra aproximación busca el patrón de la misma señal que en comparación de estos trabajos que tienen modelos entrenados con señales de otros pacientes que intervienen en cierta medida en el proceso de clasificación por la gran variabilidad de las señales. Finalmente, en Wiens *et al.* [32] presenta el resultado de un software hecho por HAMILTON software usando la base de datos del MITBIH. Este software en base a reglas tiene resultados muy similares a nuestra aproximación, pero no los supera. La ventaja del software no requiere

entrenamiento y presenta un  $S$  mayor que le nuestro, sin embargo, el  $P^+$  es cerca de 0.79, disminuyendo el valor de F-score.

En la figura 15 se muestra el performance de nuestro algoritmo para 109 pacientes que tiene al menos 40 latidos de origen ventricular. Tomando en cuenta que estas señales son de 30 min, con alrededor de 1500 a 2500 latidos por señal, con la gran mayoría de latidos normales, es claro que se necesita una muestra significativa de latidos de origen ventricular dentro de toda la señal para que el algoritmo de aglomerado pueda juntar en un grupo los distintos tipos de latidos.



**Figura 15** Histograma mostrando el F-score para LoV los 109 pacientes de la base de datos que contiene al menos 40 latidos de origen ventricular

## **8. CONCLUSIÓN**

Los 109 pacientes representan la gran mayoría de latidos de origen ventricular dentro de las tres bases de datos. El histograma muestra que 89 de los 109 tiene cuando menos un 0.85 de F-score y 60 de los 109 están por encima de 0.95 de F-score. Esto quiere decir que nuestro método trabaja cerca de 100% con más de la mitad de los pacientes que tienen un número considerable de LoV y alrededor del 80% de estos pacientes tiene un F-score de 0.85%.

## REFERENCIAS

- [1]. J. MJ, Rosen MR; 2006, History of arrhythmias, *Handb. Exp. Pharmacol.* 1–39.
- [2]. Jalife J. 2000. Ventricular fibrillation: mechanisms of initiation and maintenance. *Annu. Rev. Physiol.* Vol. 62, 25–50.
- [3] Z. Qu, J. N. Weiss; 2015; Mechanisms of Ventricular Arrhythmias: From Molecular Fluctuations to Electrical Turbulence, *Annu. Rev. Physiol.* Vol. 77, 29–55.
- [4] Priori S.G., Napolitano C.; 2004, Genetics of cardiac arrhythmias and sudden cardiac death, *Ann. N. Y. Acad. Sci.* Vol. 1015, 96–110.
- [5] Dirección General de Epidemiología, DGE 2015, Sección DGA Epidemiología, Información Epidemiológica, Publicaciones 2015, Panorama Epidemiológico y Estadístico de la Mortalidad en México 2011. Disponible en:  
<http://www.epidemiologia.salud.gob.mx/dgae/infoepid/publicaciones2015.html>
- [6] Instituto Nacional de Estadística y Geografía, INEGI 2012, Estadísticas Vitales, Tabuladores Baja California. Principales Causas de Mortalidad por residencia habitual, grupos de edad y sexo del fallecido, 2009, 2010, 2011, 2012.
- [7] K. Nikus, J. Lhteenmki, P. Lehto, M. Eskola; 2009, The role of continuous monitoring in a 24/7 telecardiology consultation service-a feasibility study. *Journal of Electrocardiology*, Vol. 42, 473 -480.
- [8] G. D. Clird, F. Azuaje, P. McSharry; 2006. *Advanced Methods And Tools for ECG Data Analysis* Artech House, Inc., Norwood, MA, USA.
- [9] Velic M., Padavic I., Car S; 2013, Computer Aided ECG Analysis - State of the Art and Upcoming Challenges, *IEEE*, 1778-1784.
- [10] ACC/AHA/ESC 2013 Heart disease and stroke statistics--2013 update: a report from the American Heart Association.
- [11] D. Nabil, F. B. Reguig; 2015, Ectopic beats detection and correction methods: A review, *Biomedical Signal Processing and Control*, Vol. 18, 228-244.
- [12] Luz E. J. da S., Schwartz W. R., Camara-Chavez G., Menotti D., 2016, ECG-based heartbeat classification for arrhythmia detection: A survey, *Computer Methods and Programs in Medicine*, vol. 127, pp. 144–164, Aug. 2016 .

- [13] Daamouche A., Hamami L., Alajlan N., Melgani F., 2012, A wavelet optimization approach for ECG signal classification, *Biomedical Signal Processing and Control*, Vol. 7.
- [14] Nazarahari M., Namin S.G., Davaie Markazi A. H., Anaraki A. K., 2015, A multi-wavelet optimization approach using similarity measures for electrocardiogram signal classification, *Biomedical Signal Processing and Control*, Vol. 20.
- [15] Mar T., Zaunseder S., Martínez J. P. ,Llamedo M., Poll R., 2011, Optimization of ECG Classification by Means of Feature Selection, *IEEE Transactions on Biomedical Engineering*, Vol. 58.
- [16] Martis R. J., Rajendra Acharya U., Prasad H., Chua C. K., Lim C. M, Suri J. S., 2013, Application of higher order statistics for atrial arrhythmia classification, *Biomedical Signal Processing and Control*, Vol. 8.
- [17] Elhaj F. A., Salim N., Harris A. R., Swee T. T., Ahmed T., 2016, Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals, *Computer Methods and Programs in Biomedicine*, Vol. 127.
- [18] Campos Oliveira L. S. , Varejao Andreao R., Sarcinelli Filho M., 2016, Bayesian Network with Decision Threshold for Heart Beat Classification, *IEEE Latin America Transactions*, Vol. 14.
- [19] Ghorbani Afkhami R., Azarnia G., Ali Tinati M., 2016, Cardiac arrhythmia classification using statistical and mixture modeling features of ECG signals, *Pattern Recognition Letters*, Vol. 70.
- [20] Martis R. J., Rajendra Acharya U. , Mandana K.M. , Ray A.K., Chakraborty C., 2013, Cardiac decision making using higher order spectra, *Biomedical Signal Processing and Control*, Vol. 8.
- [21] Javadi M., Abbaszadeh Arani S. A. A., Sajedin A., Ebrahimpour R., 2013, Classification of ECG arrhythmia by a modular neural network based on Mixture of Experts and Negatively Correlated Learning, *Biomedical Signal Processing and Control*, Vol. 8.
- [22] Lamine Talbi M., Ravier P., 2016, Detection of PVC in ECG signals using fractional linear prediction, *Biomedical Signal Processing and Control*, Vol. 23.
- [23] C. Kamath, 2011, ECG beat classification using features extracted from teager energy functions in time and frequency domains, *IET Signal Processing*, Vol. 5.

- [24] Martis R. J., Rajendra Acharya U., Choo Min L., 2013, ECG beat classification using PCA, LDA, ICA and Discrete Wavelet Transform, Biomedical Signal Processing and Control, Vol. 8.
- [25] P. Sharma, K. C. Ray, Efficient methodology for electrocardiogram beat classification, IET Signal Processing, Vol. 10.
- [26] Maji U., Mitra M., Pal S., 2016, Imposed target based modification of Taguchi method for feature optimisation with application in arrhythmia beat detection, Expert Systems with Applications, Vol. 56.
- [27] Kim Y. J., Heo J., Suk Park K., Kim S., 2016, Proposition of novel classification approach and features for improved real-time arrhythmia monitoring, Computers in Biology and Medicine, Vol. 75.
- [28] Chazal P., Dwyer M. O., Reilly R. B., 2004, Automatic classification of heartbeats using ECG morphology and heartbeat interval features, IEEE Trans. Biomed. Eng., Vol. 51, no. 7, pp. 1196–1206, Jul. 2004.
- [29] Llamedo M., Martinez J. P., 2011, Heartbeat classification using feature selection driven by database generalization criteria, IEEE Trans. Biomed. Eng., vol. 58, no. 3, pp. 616–625, Mar. 2011.
- [30] Ye C., Vijaya Kumar B. V. K., Coimbra M. T., 2012, Heartbeat Classification Using Morphological and Dynamic Features of ECG Signals, IEEE Transactions on Biomedical Engineering, vol. 59, no. 10, pp. 2930-2941, Jul. 2012.
- [31] Mar T., Zaunseder S., Martínez J. P., Llamedo M., Poll R., 2011, Optimization of ECG Classification by Means of Feature Selection, IEEE Transactions on Biomedical Engineering, vol. 58, no. 8, pp. 2168–2177, Aug. 2011.
- [32] Wiens J., Gutttag J. V., 2010, Active learning applied to patient-adaptive heartbeat classification, NIPS'10 Proceedings of the 23rd International Conference on Neural Information Processing Systems.
- [33] World Health Organization, Fact Sheet No. 317 “Cardiovascular diseases”, 2015, disponible en: <http://www.who.int/mediacentre/factsheets/fs317/en/>
- [34] ACC/AHA/ESC 2006 Guidelines for Management of Patients With Ventricular Arrhythmias and the Prevention of Sudden Cardiac Death.
- [35] R. Mehra; 2007, Global public health problem of sudden cardiac death, Journal of Electrocardiology, Vol. 40, 118-122 .
- [36] Sacher F., Tedrow UB., Field ME., Raymond JM., Koplán BA., Epstein

- LM, Stevenson WG.; 2008, Ventricular tachycardia ablation: evolution of patients and procedures over 8 years. *Circ Arrhythm Electrophysiol*, Vol. 1,153–161.
- [37] Yarlagadda RK, Iwai S, Stein KM, Markowitz SM, Shah BK, Cheung JW, Tan V, Lerman BB, Mittal S.; 2005 Reversal of cardiomyopathy in patients with repetitive monomorphic ventricular ectopy originating from the right ventricular outflow tract., *AHA Circulation*,112:1092–1097.
- [38] Baman TS, Lange DC, Ilg KJ, Gupta SK, Liu TY, Alguire C, Armstrong W, Good E, Chugh A, Jongnarangsin K, Pelosi F Jr, Crawford T, Ebinger M, Oral H, Morady F, Bogun F.; 2010, Relationship between burden of premature ventricular complexes and left ventricular function. *Heart Rhythm*. Vol. 7, 865– 869.
- [39] Viskin S, Rosso R, Rogowski O, Belhassen B.; 2005, The “short-coupled” variant of right ventricular outflow ventricular tachycardia: a not-so-benign form of benign ventricular tachycardia?, *J Cardiovasc Electrophysiol*, Vol. 16, 912–916.
- [40] Noda T, Shimizu W, Taguchi A, Aiba T, Satomi K, Suyama K, Kurita T, Aihara N, Kamakura S., 2005, Malignant entity of idiopathic ventricular fibrillation and polymorphic ventricular tachycardia initiated by premature extrasystoles originating from the right ventricular outflow tract, *J Am Coll Cardiol*, Vol. 46, 1288–1294.
- [41] Panidis IP, Morganroth J.; 1983, Sudden death in hospitalized patients: cardiac rhythm disturbances detected by ambulatory electrocardiographic monitoring, *J Am Coll Cardiol*, Vol. 2, 798–805.
- [42] Kempf FC Jr, Josephson ME., 1984, Cardiac arrest recorded on ambulatory electrocardiograms, *Am J Cardiol*, Vol. 53, 1577–1582.
- [43] DiMarco JP, Haines DE.; 1990, Sudden cardiac death. *Curr Probl Cardiol.*, 15:183–232.
- [44] Tisdale J, Miler DA.; 2010, *Drug-Induced Diseases: Prevention, Detection and Management*. 2nd ed. Bethesda, MD: American Society of Health System Pharmacists.
- [45] Lehmann MH, Timothy KW, Frankovich D, Fromm BS, Keating M, Locati EH, Taggart RT, Towbin JA, Moss AJ, Schwartz PJ, Vincent GM; 1997, Age gender influence on the rate-corrected QT interval and the QT-heart rate relation in families with genotypically characterized long QT syndrome. *J Am Coll Cardiol*. Vol. 29, 93–99.
- [46] White RD, Wood DL.; 1992, Out-of-hospital pleomorphic ventricular

tachycardia and resuscitation: association with acute myocardial ischemia and infarction. *Ann Emerg Med.*; Vol. 21, 1282–1287.

- [47] Brady W, Meldon S, DeBehnke D.; 1995, Comparison of prehospital monomorphic and polymorphic ventricular tachycardia: prevalence, response to therapy, and outcome. *Ann Emerg Med.*, Vol. 25, 64–70.
- [48] J.P. Kassirer.; 1976, The principles of clinical decision making: An introduction to decision analysis. *The Yale Journal of Biology and Medicine*, Vol. 49, 149–164.
- [49] W.J. Long, J.L. Griffith, H.P. Selker, and R. B. D’Agostino.; 1993, A comparison of logistic regression to decision-tree induction in a medical domain. *Comput. Biomed. Res.*, Vol. 26, 74–97.
- [50] C. Rockstroh; 2013, Novel algorithms and rating methods for high performance ECG classification (Doctorate thesis), Friedrich-Alexander Universität Erlangen-Nürnberg.
- [51] R. Silipo, C. Marchesi; 1998, Artificial neural networks for automatic ECG analysis. *IEEE Trans. Signal Proc.*, Vol. 46, 1417–1425.
- [52] M. Llamedo and J. P. Martínez, “Cross database evaluation of a multilead heartbeat classifier” *IEEE Trans. Inf. Technol. Biomed.*, vol. 16, no. 4, pp. 658-664, Jul. 2007.
- [53] Llamedo M., Martinez J. P., 2012, An Automatic Patient-Adapted ECG Heartbeat Classifier Allowing Expert Assistance, *IEEE Transactions on Biomedical Engineering*, vol. 59, no. 8, pp. 2312-2320, Aug. 2012
- [54] Al Rahhal M.M., Bazi Y., AlHichri H., Alajlan N., Melgani F., Yager R. R., 2016, “Deep learning approach for active classification of electrocardiogram signals”, *Journal Information Sciences*, vol. 345, no. C, pp. 340–354, Jun. 2016.