

UNIVERSIDAD
DE LOS ANDES

FACULTAD DE CIENCIAS ECONÓMICAS Y SOCIALES
INSTITUTO DE ESTADÍSTICA APLICADA Y COMPUTACIÓN
PROGRAMA DE MAESTRIA EN ESTADÍSTICA

www.bdigital.ula.ve

IDENTIFICACIÓN DE COMPLEJOS QRS DEL
ELECTROCARDIOGRAMA A TRAVÉS DE
MÁQUINAS DE SOPORTE VECTORIAL

Autor: Rossana Timaure
Tutor: PhD. Luciano Maldonado

SERBIULA
Tullio Febres Cordero

DONACION

MÉRIDA, VENEZUELA

IDENTIFICACIÓN DE COMPLEJOS QRS DEL ELECTROCARDIOGRAMA A TRAVÉS DE MÁQUINAS DE SOPORTE VECTORIAL.

RESUMEN. En este trabajo se construyeron y probaron programas clasificadores basados en máquinas de soporte vectorial (MSV) para la identificación de complejos QRS de un electrocardiograma. Las pruebas se realizaron utilizando una muestra de 16 registros de 30 minutos de duración, 8 provenientes de hombres y 8 de mujeres pertenecientes a la base de datos de arritmias cardíacas del Instituto Tecnológico de Massachusetts, cada registro fue filtrado utilizando un filtro digital de primer orden con ancho de banda entre 4 y 15 Hz, posteriormente a cada latido cardíaco se le calcularon los parámetros: duración de la onda P, intervalo PR, duración del QRS, duración del intervalo QT, duración de la onda T, duración del intervalo RR, amplitud de onda QR y amplitud de onda RS, recomendados por la Asociación Americana del Corazón para el estudio de arritmias. Se trabajó con 28.829 latidos normales, 755 con Contracción Ventricular Prematura (PVC), 516 con Contracción Atrial Prematura (APC), 4106 latidos PACED y 505 latidos de otros tipos. Estos patrones fueron utilizados para construir y evaluar los clasificadores con funciones *kernel* lineal, polinómica y de base radial gaussiana (RBF). La programación se realizó en MATLAB®, utilizando las librerías de optimización mexSVMTrain y mexSVMTest disponibles gratuitamente en LIBSVM. La evaluación se realizó utilizando validación cruzada, ofreciendo el mejor desempeño el clasificador construido con función *kernel* RBF, con $\gamma=3$, $\epsilon=0,001$ y $C=1$, el cual presentó una tasa de clasificación del 99 % para QRS normales y PACED, 97 % para PVC y de 60 % para APC y un 90 % de exactitud de clasificación para estos tipos de latidos.

PALABRAS CLAVES: Máquinas de soporte vectorial, Electrocardiograma (ECG), reconocimiento de patrones, complejos QRS, arritmias

ÍNDICE GENERAL

	P-P
1. Planteamiento del problema	
1.1. Planteamiento del problema.	01
1.2. Formulación del problema.	03
1.3. Antecedentes.	03
1.3.1. Algunos antecedentes internacionales.	03
1.3.2. Algunos antecedentes nacionales.	04
1.4. Justificación.	04
1.4. Objetivo general.	06
1.4. Objetivos específicos.	06
2. Marco Teórico	
2.1. Anatomía funcional y actividad eléctrica del corazón.	07
2.2. Despolarización repolarización del corazón.	09
2.3. Arritmias cardíacas.	14
2.4. Base de datos del Instituto Tecnológico de Massachussets.	17
2.5. Aprendizaje estadístico.	17
2.6. Máquinas de soporte vectorial.	20
2.6.1. Máquinas de soporte vectorial para clasificación.	20
2.6.2. Máquinas de soporte vectorial para clasificación binaria.	21
2.6.3. Máquinas de soporte vectorial con margen máximo.	22
2.6.4. Formulación original de la MSV.	22
2.6.5. Formulación dual de la MSV.	24
2.6.6. Máquinas de soporte vectorial con margen máximo en el espacio de características.	25
2.6.7. Máquinas de soporte vectorial con margen blando.	27
2.6.8. Máquinas de soporte vectorial para multclasificación.	29
2.7. Evaluación de los clasificadores.	30
2.7.1. Evaluación mediante validación cruzada.	31
3. Metodología	
3.1. Identificación del tipo de investigación desarrollada.	33
3.2. Revisión de los aspectos teóricos y técnicos del reconocimiento de patrones y señales ECG.	33

	p.p
3.3. Descripción de los datos.	34
3.4. Obtención de patrones para la clasificación de señales ECG.	37
3.5. Validación de la obtención de patrones para la clasificación de señales ECG.	37
3.6. Diseño y desarrollo de los algoritmos para la clasificación de complejos QRS normales y anormales de señales electrocardiográficas.	37
3.7. Validación y evaluación de los algoritmos de clasificación.	38
4. Adquisición de datos y pruebas realizadas	
4.1. Carga de los datos de la base de datos del MIT-BIH.	39
4.2. Obtención de los parámetros (patrones) de los registros ECG.	40
4.2.1. Filtrado digital.	41
4.2.2. Detección del complejo PQRST.	44
4.2.3. Obtención de los patrones del complejo PQRST.	47
4.2.3.1. Patrones de complejos QRS normales.	48
4.2.3.2. Patrones de complejos QRS con episodios de contracción ventricular prematura.	50
4.2.3.3. Patrones de complejos QRS con episodios de contracción auricular prematura.	51
4.2.3.3. Patrones de latidos PACED.	52
4.3. Diseño de un clasificador de latidos cardíacos basado en máquinas de soporte vectorial.	53
4.3.1. Etapa de entrenamiento, construcción del clasificador.	54
4.3.2. Evaluación del clasificador.	58
4.3.3. Entrenamiento del primer caso de prueba.	60
4.3.4. Evaluación del primer caso de prueba.	62
4.3.5. Entrenamiento del segundo caso de prueba.	64
4.3.6. Selección de la función <i>kernel</i> .	66
5. Conclusiones y recomendaciones.	70
Referencias bibliográficas.	72
Anexos.	78

ÍNDICE DE FIGURAS

	p.p
Figura 1. Diagrama del corazón.	08
Figura 2. Dinámica de generación en el músculo cardíaco de ECG.	10
Figura 3. Configuración en el plano horizontal de las derivaciones del ECG.	11
Figura 4. Ubicación estándar de los electrodos en el plano frontal para la obtención del ECG.	12
Figura 5. Ciclo cardíaco, complejo QRS.	13
Figura 6. ECG en presencia de contracciones ventriculares prematuras.	15
Figura 7. ECG en presencia de contracciones supraventriculares prematuras.	16
Figura 8. ECG en presencia de latido atrial prematuro.	16
Figura 9. Especificación de los archivos .hea, .dat y .atr, de la base de datos de arritmias cardíacas del MIT-BIH.	19
Figura 10. Ilustración de los vectores de soporte e hiperplano.	21
Figura 11. Ilustración de un conjunto de observaciones no linealmente separables.	23
Figura 12. Evaluación mediante validación cruzada.	31
Figura 13. Trazo de un registro ECG proveniente de la base de datos del MIT- BIH con sus respectivas anotaciones.	35
Figura 14. Metodología para la implementación de un sistema de clasificación basado en máquinas de soporte vectorial.	37
Figura 15. Diagrama de flujo de la función Carga.m.	40
Figura 16. Parámetros calculados para la caracterización de los complejos PQRST de un ECG.	41
Figura 17. Rangos de frecuencia de los complejos QRS.	42
Figura 18. Diagrama de flujo de la función filtro.m.	43
Figura 19. Prueba de la función filtro.m con una señal senoidal.	44
Figura 20. Señal ECG luego de aplicado el filtro derivador.	45
Figura 21. Señal de entrada y de salida de la función integradora.	46
Figura 22. Detacción de los picos R en un complejo QRS.	46

	P-P
Figura 23. Patrones detectados en un complejo PQRST.	47
Figura 24. Arquitectura del clasificador de complejos QRS basado en MSV.	53
Figura 25. Diagrama de flujo de la función clasifica.m	55
Figura 26. Diagrama de flujo de la función mexSVMtrain.m	57
Figura 27. Vectores de complejos QRS normales y con APC de los registros 100, 209 y 220.	63
Figura 28. Medidas de evaluación del clasificador implementado en este trabajo con <i>kernel</i> RBF $\gamma \geq 3$.	69

www.bdigital.ula.ve

ÍNDICE DE TABLAS

		P-P
Tabla 1.	Códigos de anotaciones de la base de arritmias cardíacas del MIT-BIH.	18
Tabla 2.	Descripción de los registros de la base de datos de arritmias del MIT-BIH.	34
Tabla 3.	Número de complejos PQRST según algunos tipos por cada registro.	36
Tabla 4.	Descripción de variables de entrada y salida de la función Carga.m.	39
Tabla 5.	Descripción de las variables de la función filtro.m.	42
Tabla 6.	Tabla resumen de los parámetros de complejos QRS normales del registro 103 de la base de datos de arritmias cardíacas del MIT-BIH	48
Tabla 7.	Distribución de los tipos de complejos QRS, que fueron parametrizados en 16 registros de la base de datos de Arritmias Cardíacas del MIT BIH.	48
Tabla 8.	Resumen de los patrones QRS, ST, RR, de complejos QRS normales.	49
Tabla 9.	Resumen de los patrones QRS y DP de complejos QRS con PVC.	51
Tabla 10.	Resumen de los patrones de complejos QRS con contracción auricular prematura.	52
Tabla 11.	Resumen de los patrones de complejos QRS PACED.	52
Tabla 12.	Descripción de las variables de la función clasifica.m.	54
Tabla 13.	Valores preestablecidos por defecto para las variables de entrada en el proceso de entrenamiento.	56
Tabla 14.	Descripción de las variables de la función prueba.m.	60
Tabla 15.	Patrones de entrenamiento utilizados para el primer caso de prueba.	61
Tabla 16.	Resultados del entrenamiento en el primer caso de prueba.	61
Tabla 17.	Patrones utilizados para consulta y evaluación el primer caso de prueba.	62

Tabla 18.	Medidas de evaluación de los clasificadores entrenados en el primer caso de prueba.	64
Tabla 19.	Patrones utilizados en el segundo caso de prueba.	65
Tabla 20.	Resultados del entrenamiento en el segundo caso de prueba.	65
Tabla 21.	Resumen de la evaluación del segundo caso de prueba.	65
Tabla 22.	Medidas de precisión de los clasificadores generados en el segundo caso de prueba.	66
Tabla 23.	Matrices de confusión obtenida de los multclasificadores optimizados en el segundo caso de pruebas.	67
Tabla 24.	Comparación de las medidas de calidad de clasificación entre el clasificador implementado y el desarrollado por Yun-Chi Yeh <i>et at.</i>	68

www.bdigital.ula.ve

CAPÍTULO I

PLANTEAMIENTO DEL PROBLEMA

"El verdadero acto del descubrimiento no consiste en salir a buscar nuevas tierras, sino en aprender a ver la vieja tierra con nuevos ojos." Marcel Proust

1.1. Planteamiento del problema.

Las enfermedades cardiovasculares son la principal causa de muerte alrededor del mundo, según la Organización Mundial de la Salud en el 2005 fallecieron por esta causa 17,5 millones de personas, lo que representó un 30 % de los decesos registrados alrededor del mundo; 7,6 millones de esas muertes se debieron a la cardiopatía coronaria y 5,7 millones corresponden con los accidentes vasculares cerebrales [1]. En el año 2009, según la Organización Panamericana de la Salud las enfermedades cardiovasculares representaron el 10 % del total de la carga mundial de morbilidad [2].

Para el diagnóstico y seguimiento de las enfermedades cardiovasculares se utiliza el electrocardiograma (ECG), que es un procedimiento sencillo, rápido y no invasivo, que mide la actividad eléctrica del corazón representada por el complejo QRS, el cual es una estructura en el ECG que corresponde en el tiempo con la despolarización de los ventrículos. El electrocardiograma permite conocer si un corazón funciona normalmente o si presenta anomalías como latidos extra, arritmias, entre otros [3]. Para la lectura e interpretación de un electrocardiograma se debe tener en cuenta principalmente el análisis del ritmo cardíaco, sus descriptores o características más importantes, las cuales se obtienen a partir de la evaluación morfológica de los latidos cardíacos o complejos QRS, utilizando métodos de reconocimiento de patrones.

El ritmo normal se conoce como sinusal y el anormal como no sinusal o arritmia. Entre los latidos anormales se tienen las contracciones ventriculares prematuras (PVC), que son una condición en la que se origina una señal eléctrica en los ventrículos y hace que éstos se contraigan antes de recibir la señal eléctrica

de los atrios. Si la frecuencia de las PVC aumenta hasta varias por minuto, pueden aparecer síntomas como debilidad, fatiga, mareos, desmayos o palpitaciones. Otras arritmias frecuentes son las contracciones supraventriculares prematuras o contracciones atriales prematuras (APC), que son una condición en la cual el sitio del marcapasos auricular, por encima de los ventrículos, emite una señal eléctrica temprana [4]. Generalmente, los ventrículos tienen la capacidad de responder a esta señal, pero el resultado es un ritmo cardíaco irregular.

Actualmente, se realizan numerosos estudios orientados al análisis de la efectividad en la aplicación de técnicas estadísticas, así como de métodos basados en inteligencia artificial para la clasificación de bioseñales (electrocardiograma ECG, Electroencefalograma EEG, Electromiograma, etc); entre ellas se presentan las Máquinas de Soporte Vectorial (*Support Vector Machine*, MSV) como técnica de aprendizaje estadístico [5], las cuales son algoritmos emergentes utilizados exitosamente en problemas de clasificación y regresión, su fundamento matemático es debido a Vapnik en 1964 y generalizado en los años 1990 [6]. Las MSV, presentan claras ventajas respecto a los clasificadores discriminativos tradicionales ya que pertenecen a la familia de clasificadores de gran margen y su principal característica es que minimizan simultáneamente el error de clasificación empírico (Minimización del riesgo empírico) y maximizan el margen geométrico entre muestras de diferentes clases (Minimización del Riesgo Estructural). La minimización del riesgo estructural se basa en controlar el compromiso entre la complejidad de la función de decisión (capacidad del modelo) y los errores de clasificación en los datos de entrenamiento. Por esta razón, las máquinas de soporte vectorial son un procedimiento discriminativo de gran éxito que ha sido utilizado en numerosas tareas de reconocimiento de patrones [7].

La etapa de clasificación en el reconocimiento de patrones es una de las más importantes, pues permite determinar si los parámetros resultantes de la etapa de caracterización son discriminantes y evaluar el sistema frente a datos con ruido y perturbaciones externas [8]. Es por eso que surge la necesidad de encontrar clasificadores que no sólo sean robustos al ruido presente en los datos de entrada, sino también que se adapten de acuerdo a la variabilidad de estos datos, características que están presentes en los clasificadores basados en máquinas de soporte vectorial [9].

En el caso de los complejos QRS de un electrocardiograma hay presencia de ruido e interferencia que provienen de la red de distribución eléctrica, equipos eléctricos o electrónicos próximos al entorno de medida y de la variabilidad propia en los sistemas biológicos, donde los complejos ECG son desde el punto de vista estadístico, producidos por procesos estocásticos.

Por estas razones se propuso implementar una máquina de soporte vectorial para la multclasificación de latidos cardíacos normales y latidos cardíacos característicos de episodios de contracciones ventriculares prematuras (PVC), contracciones supraventriculares prematuras (APC) y latidos PACED.

1.2. Formulación del problema.

En esta investigación se pretendía determinar la eficiencia de las máquinas de soporte vectorial para la clasificación de patrones asociados a las características de complejos QRS de latidos normales e indicadores de episodios de contracciones ventriculares prematuras (PVC), contracciones supraventriculares prematuras (APC), latido PACED, latidos de fusión y latidos desconocidos, considerando a estos últimos aquellos que son ruido o cambio de ritmo en la señal ECG.

1.3. Antecedentes.

Los investigadores del campo aquí abordado han estudiado muchas técnicas para la evaluación y clasificación de arritmias cardíacas, entre ellas, la transformada de Hilbert [10], los modelos ocultos de Markov [11], la transformada Wavelet [12], el análisis discriminante lineal [13], las redes neuronales [14]. Todas estas herramientas ofrecen rangos de sensibilidad alto, pero algunos tienen un costo elevado en recursos de computación y complejidad. Hoy constituye una de las técnicas que se referencian por su alta capacidad discriminante son las máquinas de soporte vectorial; se pueden citar entre sus aplicaciones la clasificación de señales biomédicas, como las electromiográficas, electroencefalográficas [15] y las electrocardiográficas, como se evidencia en los trabajos que se referencian a continuación.

1.3.1. Algunos antecedentes internacionales

Elif Derya Übeyli en 2006, presentó el trabajo "Clasificación de latidos cardíacos

usando máquinas de soporte vectorial para multclasificación con códigos de corrección de errores en la salida” [16], en el cual se clasifican cuatro tipos de latidos ECG (ritmo normal, insuficiencia cardíaca congestiva, taquiarritmia ventricular y fibrilación auricular) obtenidos de la base de datos del Physiobank (Instituto Tecnológico de Massachusetts y el Hospital Beth Israel, MIT-BIH). En este trabajo las señales electrocardiográficas fueron descompuestas en representaciones tiempo-frecuencia utilizando Transformadas Wavelet Discreta (TPM) y calcularon los coeficientes para representar las señales. Esa investigación demostró que los coeficientes Wavelet pueden representar las señales de ECG y que las MSV multiclase pueden clasificar con gran precisión estas características.

Acir Nurettin en 2006, presentó el trabajo ”Algoritmo clasificador basado en máquinas de soporte vectorial por el método de perturbación y su aplicación a los sistemas de reconocimiento de ritmo ECG” [17], esta investigación se fundamentó en obtener características de la señal utilizando Transformada Wavelet Discreta y amplitudes de los diferentes coeficientes para clasificar entre un latido normal, bloqueo del ventrículo izquierdo, contracción ventricular prematura y ausencia de la onda P, el método propuesto por Acir presentó una precisión del 96.5 %.

1.3.1. Algunos antecedentes nacionales

Sejías C., Caralli, A y Villazana, S. en 2008, presentaron su trabajo ”Agrupamiento basado en máquinas de vectores de soporte de señales ECG normales y patológicas” [8]; en este trabajo las señales ECG fueron preprocesadas utilizando complejidad Lempel Ziv y Entropía de Shannon. En su diseño experimental utilizaron máquinas de soporte vectorial LIBSVM y compararon los resultados con un algoritmo de agrupamiento k-medias ajustado a nueve grupos, concluyendo que ambos presentan desempeños similares.

1.4. Justificación.

El procesamiento digital de señales fisiológicas, utilizando reconocimiento de patrones, busca extraer información relevante de los datos de un paciente, con el objetivo de proporcionar herramientas para el diagnóstico. El procesamiento digital de una señal constituye un proceso que va más allá de su mera descripción en amplitud o frecuencia, con éste se pretende caracterizar el comportamiento no

sólo de la señal, también del sistema que la origina.

Por otro lado, el diagnóstico precoz de enfermedades permite la implementación de tratamientos oportunos, donde parte del éxito depende de conocimiento que se tenga sobre el origen de la enfermedad [19]. Tratar de comprender, modelar y clasificar patrones que lleven a discriminar cuando un sujeto está sano o sufre alguna alteración del Sistema Cardiovascular, no resulta nada fácil. El análisis automatizado de los electrocardiogramas (ECG) ha sido entre las primeras aplicaciones de las computadoras en la medicina, los primeros programas de computador para la interpretación del ECG aparecieron en los años de la década de los 60, del siglo anterior [20]. Desde entonces, avances tecnológicos en combinación con el aumento de técnicas para el análisis de señales y el reconocimiento de patrones han hecho que los algoritmos para la caracterización, clasificación y predicción sobre la señal ECG sea una de las aplicaciones más utilizadas en el cuidado de la salud.

En las últimas décadas, el papel de la ECG ha sido fundamental en el caso del paciente coronario agudo, epidemiológico y clínico; los patrones del ECG mostraron ser importantes indicadores de riesgo. En esos estudios el ECG, hasta los momentos, es la prueba de elección, debido a su carácter no invasivo, la facilidad de digitalización y su bajo costo. Además, su exploración permite el estudio de nuevas mediciones de interés potencial, sin embargo el ECG es una señal no estacionaria, donde los eventos de interés se producen de forma aleatoria en el tiempo. En esta situación, los síntomas de una enfermedad pueden no aparecer todo el tiempo, sino que se manifiestan en intervalos irregulares durante el día. Por lo tanto, la eficacia de los diagnósticos, en el estudio de los patrones del ECG conlleva varias horas lo que implica que el volumen de los datos es muy grande y el estudio es tedioso [21][22]. Naturalmente, el procesamiento automático del ECG presenta muchas ventajas con respecto a la lectura visual (del especialista que puede sufrir de fatiga y variabilidad entre observaciones) y ofrecen importantes ahorros en tiempo y dinero.

Venezuela no escapa a la realidad mundial en cuanto al impacto de las enfermedades cardiovasculares que son diagnosticadas, tratadas y evaluadas utilizando el ECG, en el año 2006 estas enfermedades representaron el 20,63% de la mortalidad en el país, convirtiéndose en la primera causa de muerte por enfermedad [23].

En lo antes expuesto radica la importancia de abordar este campo de investigación recurriendo al uso de técnicas emergentes en el tratamiento y reconocimiento de patrones.

1.5. Objetivo general.

Implementar una máquina de soporte vectorial para la multclasificación de complejos QRS en un electrocardiograma.

1.6. Objetivos específicos.

- Analizar criterios para la clasificación de complejos QRS de estados normales y episodios de arritmias en un electrocardiograma.
- Determinar patrones que permitan la clasificación de complejos QRS de estados normales y episodios de arritmias en un electrocardiograma.
- Desarrollar programas para la obtención de los patrones para la clasificación de complejos QRS de un electrocardiograma.
- Estudiar la teoría relacionada con máquinas de soporte vectorial.
- Revisar software que permita implementar máquinas de soporte vectorial.
- Implementar máquinas de soporte vectorial para la clasificación de señales electrocardiograficas.
- Evaluar los resultados obtenidos en la clasificación de complejos QRS de estados normales y episodios de arritmias en un electrocardiograma utilizando máquinas de soporte vectorial.

CAPÍTULO II

MARCO TEÓRICO

"Cualquier idea simple se puede expresar de la manera más compleja que existe" Ley de Murphy.

Para entender el origen y el significado del electrocardiograma (ECG), es importante comprender los fenómenos eléctricos y físicos que ocasionan el potencial eléctrico que en él se registran, es por esto que a continuación se describen brevemente los principios de funcionamiento del corazón.

2.1. Anatomía funcional y actividad eléctrica del corazón.

El corazón es como una bomba electromecánica, es decir, un sistema que genera de forma automática el impulso cardíaco y lo transmite a todas las células de trabajo denominadas miocitos y éstas con su contracción o acortamiento impulsan la sangre para que se distribuya por todo el organismo. Los miocitos son las células cardíacas que conforman el tejido contráctil que genera el impulso cardíaco, este tejido es altamente especializado y exclusivo del corazón, por lo que es importante para la comprensión de su funcionamiento, el conocimiento de su morfología [24].

Son varias las estructuras que conforman el sistema de conducción, como se observa en la Figura 1, una de estas estructuras es el nódulo sinuauricular(SA), el cual constituye el marcapasos cardíaco en condiciones normales [25].

Las vías de conducción entre los nódulos sinuauricular y aurículo ventricular (AV), son llamadas miocardio auricular internodal y la vía interauricular que conduce el impulso cardíaco desde el nódulo sinuauricular hasta la aurícula izquierda es llamada Haz de Bachmann.

El nódulo AV cumple las funciones de marcapasos cardíaco cuando no es posible que las realice el nódulo sinuauricular.

Desde el nódulo AV surge una vía conductora que se dirige hacia el tejido ventricular denominada Haz de Hiz. Al llegar a los ventrículos se divide en dos ramas una hacia cada ventrículo y éstas a su vez, se subdividen hasta formar una red que rodea la mayor parte del miocardio ventricular. Esta ramificación es la encargada de hacer llegar el impulso eléctrico al tejido muscular ventricular y recibe el nombre de Red de Purkinje [25].

Hasta ahora se ha podido distinguir la participación de distintos tipos de células en la actividad eléctrica del corazón las cuales son clasificadas en células automáticas y células de trabajo. Las células automáticas o de respuesta lenta, además de ser las encargadas de transportar el impulso eléctrico, tienen la capacidad de generarlo espontáneamente. Estas células poseen un potencial de reposo inestable que hace que se puedan despolarizar de forma automática, logrando un potencial umbral que causa finalmente un potencial de acción que luego se transmite a las células próximas.

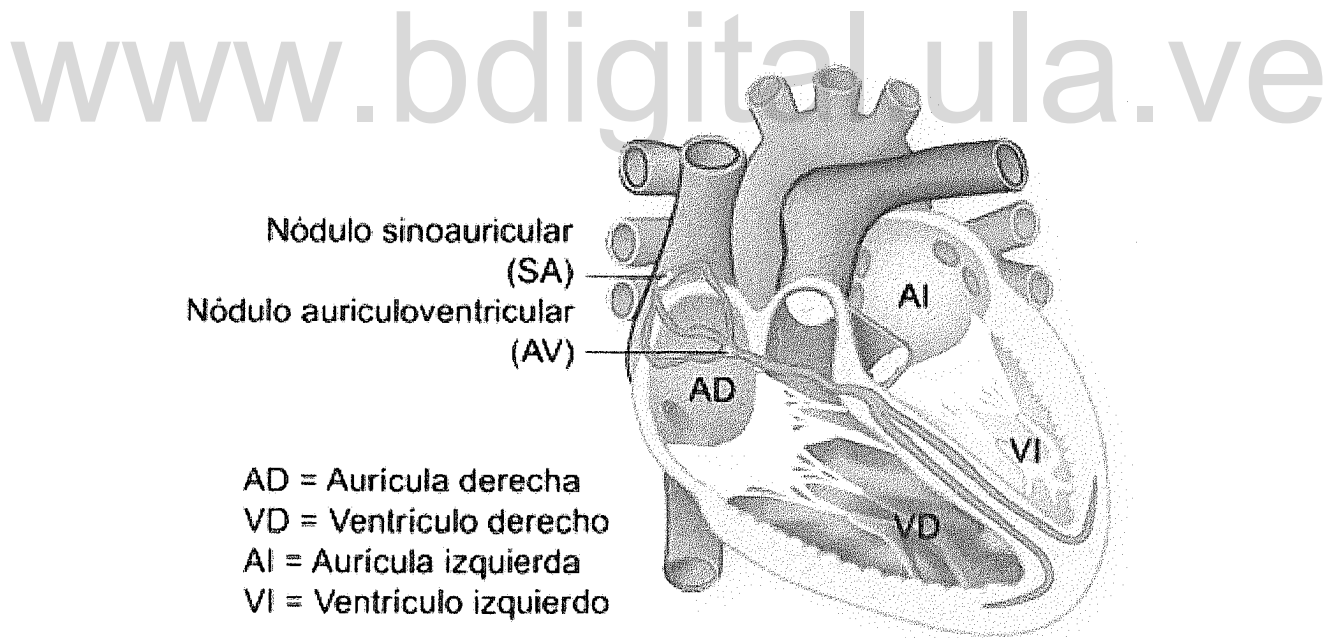


Figura 1. Diagrama del corazón [26].

Por su parte, las células de trabajo o musculares o de respuesta rápida, tales como los miocitos, son las encargadas de contraer el tejido cardíaco pero necesi-

tan de estímulo externo para lograrlo, esto es debido a que poseen un potencial de reposo estable. Dicho estímulo proviene, por lo general, de las células automáticas.

En el nódulo sinuauricular donde se origina inicialmente el potencial de acción que se transmite a través del sistema de conducción hasta la totalidad del tejido contráctil del corazón. El impulso eléctrico, pasa a través del miocardio auricular internodal y del Haz de Bachmann causando la despolarización del miocardio auricular; es decir, provoca la contracción de las aurículas. Luego que el impulso pasa por los tractos internodales llega al nódulo AV, donde aumenta el potencial de acción gracias a las células automáticas allí presentes, y parte a través del Haz de Hiz hacia la Red de Purkinje para ocasionar finalmente la despolarización del tejido muscular ventricular o, dicho de otro modo, la contracción de los ventrículos. En el mismo orden de eventos ocurre la repolarización o recuperación de las células, es decir, que luego que la célula se activa comienza a recuperarse hasta que logra el estado de reposo inicial. Lógicamente, este fenómeno ocurre primero en el nódulo sinusal y luego en las vías de conducción internodales e interauriculares. En el momento en que esto ocurre, también sucede la despolarización ventricular [25].

Todo este dinamismo eléctrico es registrado en el electrocardiograma (ECG), como se observa en la Figura 2, y es por esto que a continuación se explican los principios físicos y eléctricos que permiten realizarlo.

2.2. Despolarización y repolarización del corazón.

El corazón es recorrido por una onda progresiva de estimulación que produce la contracción del miocardio, es decir, las células cardíacas en reposo se encuentran cargadas o polarizadas, pero la estimulación eléctrica las despolariza y se contraen. En las ondas de despolarización, el interior de las células se vuelve positivo, contrario a las ondas de repolarización, en donde el interior de las células se vuelve negativo; la repolarización o recuperación es un fenómeno estrictamente eléctrico en el cual el corazón no presenta ningún movimiento [25]. El electrocardiograma está diseñado para registrar la dirección y magnitud del impulso eléctrico que se transmite por el corazón. Ya que poseen dirección y magnitud, estas corrientes eléctricas pueden ser representadas a través de vectores. El electrocardiograma muestra el vector resultante de todos los vectores de las corrientes que ocurren en

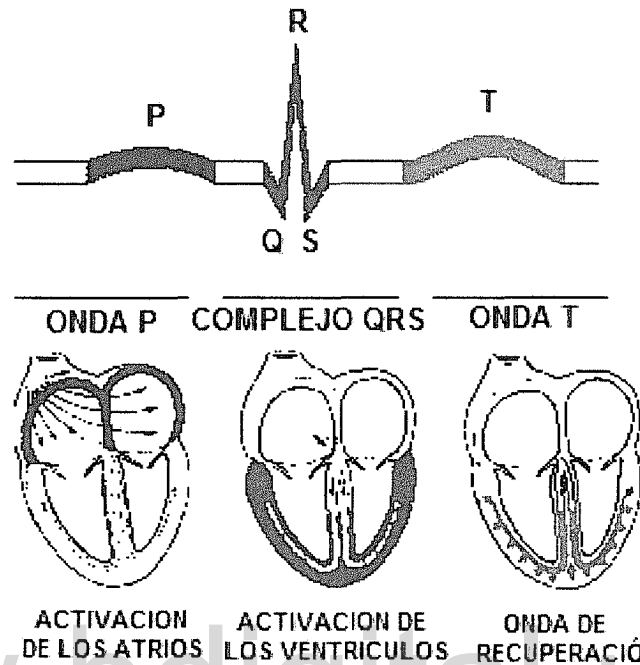


Figura 2. Dinámica de generación en el músculo cardíaco del ECG [27].

el corazón, el cual se obtiene gracias a electrodos colocados sobre la piel en distintas partes del cuerpo [28]. Convencionalmente los electrocardiógrafos realizan el registro del ECG sobre papel cuadrículado milimetrado. El papel pasa por el oscilógrafo que realiza el trazo a una velocidad estándar de 25mm./s. El oscilógrafo se desplaza en el eje de las ordenadas a razón de 10mm./mV. En la actualidad estos parámetros son ajustables y la señal que se registra es digitalizada con diferentes grados de resolución.

Los puntos de observación de la actividad eléctrica del corazón definen las derivaciones del ECG, estas son los lugares donde son colocados los electrodos [28]. En el ECG estándar de 12 derivaciones se habla de derivaciones en los planos horizontal y frontal. Las del plano horizontal son aquellos electrodos que se colocan en el tórax y a las cuales se les conoce como derivaciones unipolares precordiales, son 6 y reciben nombres desde V1 hasta V6. Las derivaciones del plano horizontal aportan mucha información cardíaca local debido a su proximidad al corazón.

En la Figura 3, se puede observar la ubicación de estos electrodos cuyas deri-

vaciones son:

- V1, cuarto espacio intercostal en el lado derecho del esternón.
- V2, cuarto espacio intercostal a la izquierda del esternón.
- V3, situación intermedia entre V2 y V4.
- V4, quinto espacio intercostal sobre la línea media.
- V5, línea axilar anterior en el nivel de la derivación V4.
- V6, línea axilar media en el nivel de la derivación V4.

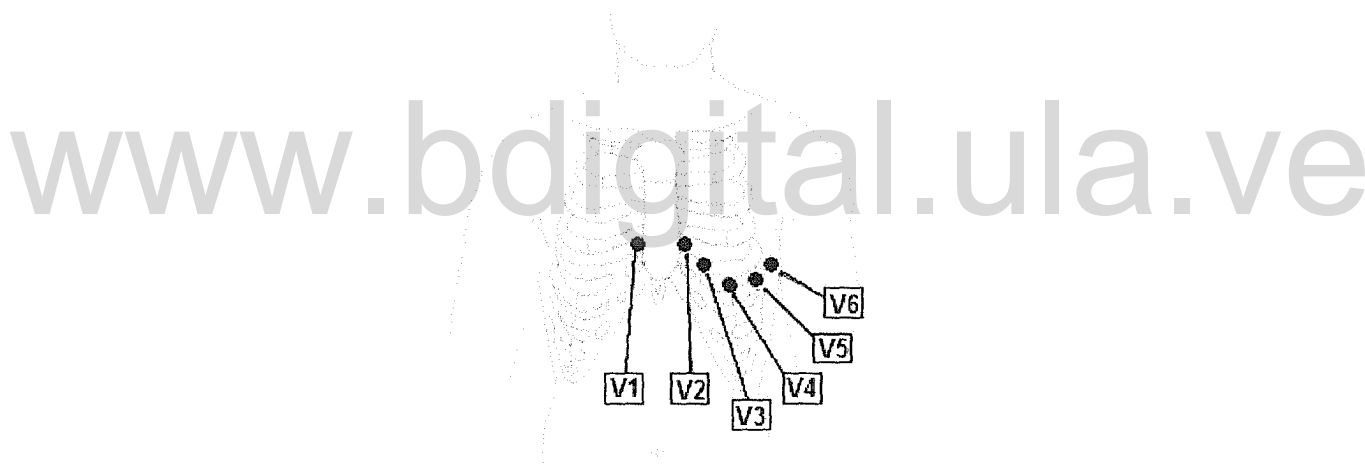


Figura 3. Configuración en el plano horizontal de las derivaciones del ECG [28].

Las derivaciones del plano frontal comprenden tres electrodos que se colocan en las extremidades y que reciben el nombre de derivaciones unipolares de los miembros, más tres derivaciones llamadas derivaciones bipolares de los miembros y que se generan a partir de la diferencia de potencial entre los electrodos de las extremidades. Los electrodos unipolares de las extremidades se colocan en el hombro derecho, en el hombro izquierdo y en la pierna izquierda recibiendo como nombres aVR, aVL y aVF respectivamente, o RA, LA y LF, como se observan en la Figura 4. Las derivaciones bipolares son D1, D2, y D3 y se forman por el registro simultáneo de aVL aVR, aVR aVF y aVL aVF. Las derivaciones del

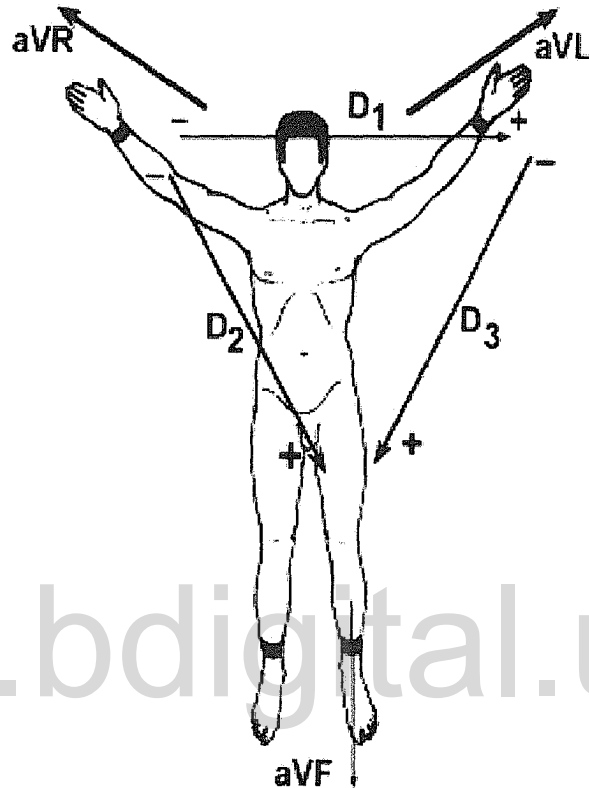


Figura 4. Ubicación estándar de los electrodos en el plano frontal para la obtención del ECG [28].

plano frontal aportan mayor información cardíaca global.

Los trazos ECG (Figura 5), que generan cada una de las derivaciones son distintos entre sí, y no todos ofrecen la misma información sobre algún fenómeno cardíaco. Sin embargo, se han caracterizado los segmentos de la onda o trazo ECG comunes entre cada ciclo cardíaco. La despolarización auricular ocasiona la onda P, cuya duración es la misma de la conducción interauricular. La onda P es positiva en D1, D2 y aVF y su altura no es mayor de 2,5 mm, con duración menor a los 0,10 s. en condiciones normales. Luego de la onda P ocurren una serie de deflexiones que se conocen como complejo QRS, ya que lo conforman la onda Q (primera deflexión negativa), la onda R (primera deflexión positiva) y la onda S (segunda deflexión negativa). La altura de las ondas R y S, indican la cantidad de masa ventricular y el tamaño de la cavidad ventricular, así como su duración es

la misma de la conducción intraventricular [28].




Figura 5. Ciclo cardíaco, complejo QRS [27].

El complejo QRS puede describirse mediante cuatro vectores:

- Vector inicial de activación septal de izquierda a derecha dirigido hacia delante, abajo o hacia arriba, seguido de otra activación septal dirigida de izquierda a derecha (0.01 s).
- Una onda superpuesta de excitación que afecta a ambos ventrículos, con el vector dirigido hacia abajo y ligeramente hacia la izquierda (0.02 s).
- Activación evidente de la punta y porción central del ventrículo izquierdo, después que la delgada pared del ventrículo derecho ha sido despolarizada, con un vector resultante dirigido hacia atrás, abajo y a la izquierda (0.04 s).
- Activación de la porción basal y posterior del ventrículo izquierdo y el tabique interventricular, con vector dirigido hacia arriba y atrás (0.06 s).

El primer vector normalmente genera la onda Q en las derivaciones bipolares y en V1, V5 y V6, además de una onda R en las derivaciones precordiales de V1 a V4. El segundo vector produce una onda R en D2, D3, V3 y V4. El tercer vector genera una onda R en D1, D2, D3, V1, VF, V5, V6 y en algunas ocasiones en V4, además de una onda S en VR, V1, V2, V3 y algunas veces V4. El cuarto vector termina la onda S en D1, V5 y V6. Derivaciones como la V4 o V1 pueden llegar a registrar una onda R.

El complejo QRS tiene duración promedio de 100 ms. Las variaciones en la amplitud y longitud del complejo QRS son indicadores de patología tales como hipertrofia ventricular y trastornos en la conducción intraventricular. También, a través del complejo QRS se puede diagnosticar: embolia pulmonar aguda, enfermedad pulmonar obstructiva crónica, trastornos de la conducción o bloqueos, aberración intraventricular, excitación prematura, depresión miocárdica, síndrome de preexcitación, entre otros. Ya que el complejo QRS representa la despolarización ventricular, sirve también en la determinación del pulso cardíaco [29].

La onda T, positiva en D1 y D2, refleja el sentido de la repolarización ventricular. Por lo general, es positiva en las derivaciones del plano horizontal [29].

2.3. Arritmias cardíacas.

Una arritmia es un ritmo anormal del corazón que provoca que éste bombee con menor eficacia [29], generalmente se dividen en dos categorías: ventriculares y supraventriculares. Las arritmias ventriculares se producen en las cavidades inferiores del corazón, denominadas ventrículos. Las arritmias supraventriculares se producen en la zona que se encuentra encima de los ventrículos, generalmente en las aurículas, que son las cavidades superiores del corazón. Los latidos irregulares pueden ser demasiado lentos (bradicardia) o demasiado rápidos (taquicardia).

Entre algunas arritmias cardíacas se encuentran:

- Contracciones ventriculares prematuras (PVC): son despolarizaciones prematuras del ventrículo, que nacen en un foco ectópico, también se les denomina extrasístole ventricular (EV) [30]; se asocian a complejos QRS prematuros de una morfología habitualmente distinta como se observa en la Figura 6, en algunos casos con una duración superior a 0,12 s. La onda T generalmente

es muy grande y de dirección contraria a la deflexión mayor del complejo QRS, que a diferencia de un latido normal es mas amplia que el segmento QR. Este complejo no va precedido de onda T prematura y la onda P sinusal correspondiente a la actividad auricular. También puede aparecer una onda P retrógrada detrás del complejo QRS.

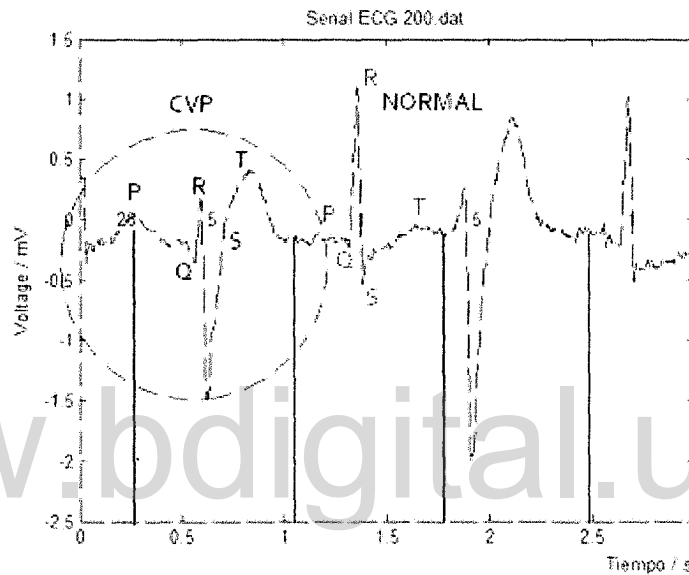


Figura 6. ECG en presencia de contracciones ventriculares prematuras.

- Contracciones supraventriculares prematuras, es una condición que se presenta cuando el nódulo sinusal o bien otro marcapasos por encima de los ventrículos envía una señal eléctrica antes de tiempo. Los ventrículos no responden a esa señal porque están todavía en la fase de contracción, son también llamadas contracciones auriculares prematuras (APC), la forma de onda característica de este tipo de arritmia se observa en la Figura 7, donde los complejos QRS son normales al igual que la onda T, pero existe irregularidad el intervalo RR y en la onda P.
- Latido atrial prematuro: es la fibrilación atrial, los atrios pierden la capacidad de contraerse correctamente, produciendo un latido del corazón irregular y rápido [31], como se observa en el Figura 8.

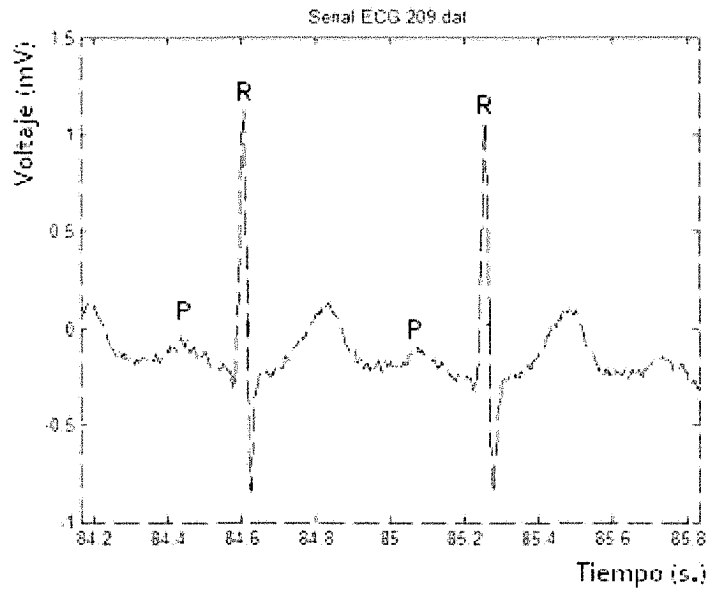


Figura 7. ECG en presencia de contracciones supraventriculares prematuras.

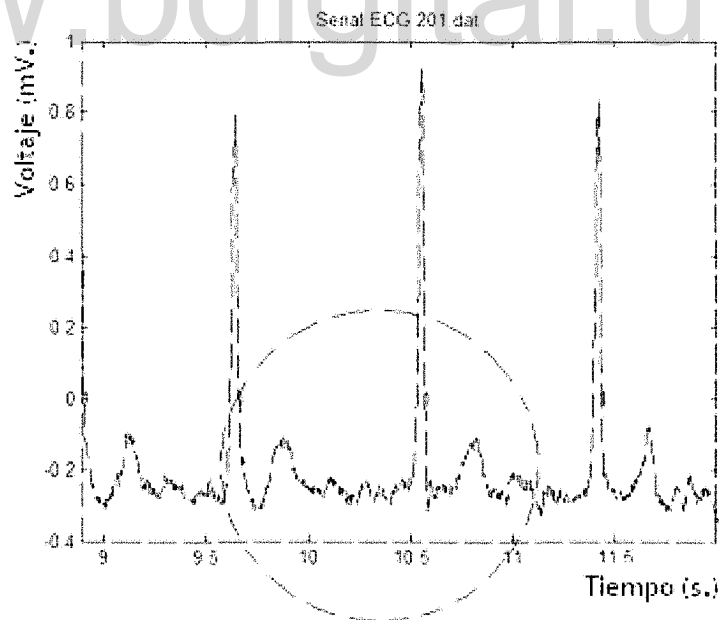


Figura 8. ECG en presencia de latido atrial prematuro.

2.4. Bases de datos del Instituto Tecnológico de Massachussets

La misión principal del Instituto Tecnológico de Massachussets (MIT) es proveer conocimiento en ciencias, tecnologías, entre otras áreas. El 33 % del MIT está dedicado al desarrollo de tecnologías para la salud, para ello cuenta con las bases de datos de señales fisiológicas digitalizadas más importantes del mundo y certificadas por médicos expertos [32]. Entre ese grupo de base de datos se encuentran:

- MIT-BIH *Arrhythmia Database*: Contiene una colección de 48 registros de ECG de media hora de dos derivaciones, incluye todas sus anotaciones y se encuentra disponible en línea [33].
- MIT-BIH *Atrial Fibrillation Database*: Contiene 23 archivos de grabaciones de 10 horas con todas sus anotaciones [34].

Cada una de estas bases de datos está compuesta por tres archivos (Figura 9), uno llamado el archivo de cabecera (.hea) que contiene información acerca del formato bajo el cual está codificada la señal, cómo fue adquirida (tipo de convertidor analógico-digital utilizado), el tipo de señal, características de los individuos (edad, sexo, medicación, diagnóstico, entre otros). Otro, denominado archivo de anotación (.atr) que contiene etiquetas o anotaciones de sucesos específicos ocurridos durante la adquisición de la señal, como por ejemplo el tiempo de ocurrencia de un latido específico del corazón, y por último los archivos (.dat), de tipo binario contienen la señal digitalizada [35]. En la Tabla 1 se muestran los tipos de latidos registrados por la MIT-BIH *Arrhythmia Database*, con la cual se desarrollan la mayoría de los trabajos de identificación de arritmias alrededor del mundo.

2.5. Aprendizaje estadístico.

Se entiende por aprendizaje a partir de ejemplos, al proceso de estimar una dependencia desconocida entrada-salida de un sistema utilizando un número limitado de observaciones. Un algoritmo de aprendizaje será aquel proceso capaz de dar respuesta a un problema a partir de ejemplos planteados, es decir, es el proceso capaz de elegir una única función a partir del conjunto de entrenamiento, dando respuesta a un problema determinado [36] [37]. Los algoritmos de aprendizaje cometen un error de generalización, el cual es la cota de la suma del error de aproximación que se comete al elegir el espacio de aproximación, más el error de estimación provocado por el conjunto de entrenamiento en el que se basa el

proceso de aprendizaje [38].

Tabla 1. Códigos de anotaciones de la base de arritmias cardíacas del MIT-BIH.

NÚMERO	DESCRIPCIÓN	CÓDIGO
0	No es latido QRS	NOTQRS
1	Latido normal	NORMAL
2	Latido de bloqueo de la rama izquierda	LBBB
3	Latido de bloqueo de la rama derecha	RBBB
4	Aberración latido prematuro auricular	ABERR
5	Contracción ventricular prematura	PVC
6	fusión de latido normal y ventricular	FUSION
7	Latido nodal prematuro	NPC
8	Contracción atrial prematura	APC
9	Latido ectópico supraventricular o prematuro	SVPB
10	Latido de escape ventricular	VESC
11	Latido escape nodal (de unión)	NESC
12	Latido PACED (ritmo)	PACED
13	Inclasificable, desconocido	UNKNOWN
14	Cambio de calidad de la señal	NOISE
16	QRS aislados como artefacto	ARFCT
18	Cambio ST	STCH
19	Cambio de onda T	TCH
20	Sístole	SYSTOLE
21	Diástole	DIASTOLE
22	Anotación de comentario	NOTE
23	Anotación de medición	MEASURE
24	Pico de onda P	PWAVE
25	Bloqueo de la rama derecha o izquierda	BBB
26	No ocurrió el Spike del marcapasos	PACESP
27	Pico onda T	TWAVE
28	Cambio de ritmo	RHYTHM
29	Pico onda U	UWAVE
30	Aprendizaje	LEARN
31	Onda de Aleteo (flutter) ventricular	FLWAV
32	Comienzo de Aleteo(flutter) /fibrilación Ventricular	VFON
33	Fin de Aleteo(flutter) /fibrilación Ventricular	VFOFF
34	Latido de escape auricular (atrial)	AESC
35	Latido de escape supraventricular	SVESC
36	Enlace de datos externo	LINK
37	No conduce onda P	NAPC
38	Fusión de ritmo y latido normal	PFUS

La teoría de aprendizaje estadístico fue desarrollada por Vapnik en 1992 y ofrece un compromiso entre los enfoques paramétrico y no paramétrico, donde la tarea

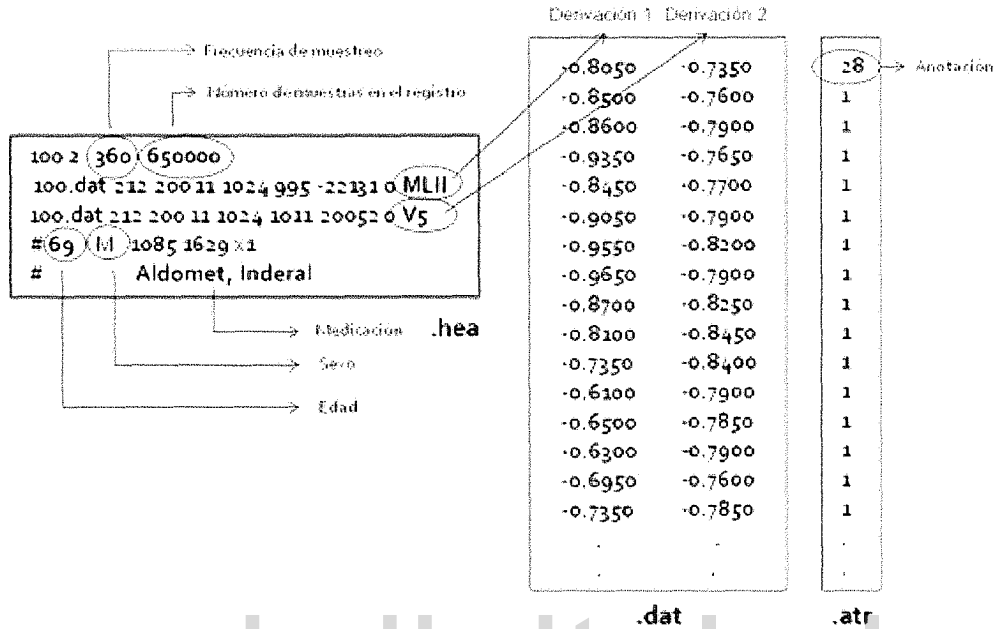


Figura 9. Especificación de los archivos .hea, .dat y .atr, de la base de datos de arritmias cardíacas del MIT-BIH.

de aprender está definida por una relación entrada-salida dada por un conjunto de datos, que es generalmente vista como el problema de elegir a partir de un conjunto dado de funciones $f(x, \alpha)$ $x \in \mathbb{R}^n$ es un vector aleatorio tomado independiente de una función de distribución de probabilidad $P(x)$, fija pero desconocida, con Λ , es un conjunto de parámetros y $\alpha \in \Lambda$, la que mejor aproxime el valor de salida y , para todos los vectores de entrada x de acuerdo a una función de distribución condicional $P(y/x)$, también fija pero desconocida [38].

La selección de la función deseada está basada en un conjunto de entrenamiento de ι observaciones, independientes e idénticamente distribuidas $(x_1, y_1)(x_\iota, y_\iota)$ tomados de acuerdo a: $P(x, y) = P(x)P(y/x)$.

Si se considera el valor esperado de las pérdidas debido a los errores de clasificación y estimación, y está dado por el riesgo funcional:

$$R(\alpha) = \int L(y, f(x, \alpha)) dP(x, y) \quad (1)$$

Donde $L(y, f(x, \alpha))$ es la discrepancia entre la respuesta medida y , y la respuesta $f(x, \alpha)$ proporcionada por la máquina de aprendizaje; la meta es encontrar una función $f(x, \alpha_0)$ que minimice el riesgo funcional $R(\alpha)$, (MRE), considerando que la única información disponible es el conjunto de datos u observaciones para el entrenamiento [39].

Esta teoría fundamenta lo que se conoce como máquinas de soporte vectorial (MSV).

2.6. Máquinas de Soporte vectorial.

Los aspectos teóricos de las máquinas de soporte vectorial se encuentran inicialmente en los trabajos de Vapnik y otros autores relacionados con la teoría del aprendizaje estadístico, estos trabajos fueron desarrollados a finales del siglo XX. El modelo SVM (*Support Vector Machine*) tal como se entiende actualmente fue presentado en la conferencia COLT (*Computational Learning Theory*) en el año 1992 por el mismo Vapnik, junto con Boser y Guyon [41]. Luego fue descrito con más detalle en el año 1995 por Vapnik y Cortes, por último en 1998 nuevamente por Vapnik.

Las máquinas de soporte vectorial tienen como objetivo solucionar aquellos problemas que surgen donde se estudian las relaciones que existen entre el sesgo y la varianza, el control de la capacidad, el sobreajuste en los datos, la clasificación binaria de elementos, entre otros. Dichos problemas consisten en indagar, para una tarea dada de aprendizaje con un conjunto finito de datos, una función apropiada con la que se pueda llevar a cabo una buena generalización que surja como el resultado de una adecuada relación entre la capacidad de un modelo y la precisión que se logra alcanzar con un conjunto específico de entrenamiento [41–44].

2.6.1. Máquinas de soporte vectorial para clasificación.

Las máquinas de soporte vectorial (MSV) se emplean en el reconocimiento de patrones, particularmente en tareas de clasificación sustentadas en el principio de minimización de riesgo estructural ofrecen buena capacidad de generalización, es

decir, tiene la capacidad de emitir respuestas correctas ante una nueva entrada semejante a aquellas con las que ha sido entrenada [45].

Las MSV son un conjunto de algoritmos utilizados con el propósito de clasificar un conjunto de observaciones. Se dice que las máquinas de soporte vectorial, debido a que inducen separadores lineales o hiperplanos, pertenecen a la familia de los clasificadores lineales. Su nombre se debe a los vectores soporte, que son aquellos puntos que están en la frontera de la región de decisión, que es donde se puede presentar la duda de a qué clase pertenece cada observación (ver Figura 10).

2.6.2. Máquinas de soporte vectorial para clasificación binaria.

Cuando se intenta clasificar un conjunto de observaciones se encuentra con que estas observaciones pueden ser o no linealmente separables. En el caso de que las observaciones sean separables linealmente, se clasifican mediante un hiperplano que divide al espacio de entrada en dos clases, digamos la clase ($y = +1$) y la clase ($y = -1$); pueden existir múltiples hiperplanos separadores. Si no son linealmente separables, el conjunto de observaciones se lleva del espacio de atributos de entrada a un espacio de características de mayor dimensión, donde se hace posible separar linealmente dichas observaciones utilizando las llamadas funciones núcleo o *kernel*.




Figura 10. Ilustración de los vectores de soporte e hiperplano.

2.6.3. Máquinas de soporte vectorial con margen máximo.

Las máquinas de soporte vectorial con margen máximo son el modelo más simple de MSV, tienen condiciones de aplicabilidad bastante restringidas. Se parte de la hipótesis que el conjunto de datos es linealmente separable en el espacio de entrada y que el clasificador que va a resultar es lineal. El término margen máximo se refiere a que todas las observaciones deben estar bien clasificadas.

Si se tiene un conjunto de observaciones linealmente separables, se pueden establecer muchos hiperplanos que clasifican o separan dichas observaciones; el mejor hiperplano separador en términos de generalización, según las MSV con margen máximo, es aquel que se encuentra a la misma distancia de las observaciones que están más cercanas a cada clase, es decir, hiperplano no puede estar sesgado hacia aquella clase que contenga más observaciones, debe ser lo más neutro posible [46].

En cuanto a las restricciones de las máquinas de soporte vectorial con margen máximo, se tiene principalmente que el clasificador resultante es lineal, y en la práctica una forma apropiada para representar un conjunto de observaciones es utilizando modelos no lineales. En la Figura 11, se muestra un ejemplo de un conjunto de observaciones en el que se requiere un clasificador no lineal.

2.6.4. Formulación original de las MSV.

Partiendo de la definición original de MSV se debe seleccionar el mejor hiperplano definido como (2):

$$h(x) = \langle \omega, x \rangle + b \quad (2)$$

Que separa los vectores x_i , con: $i=1, \dots, n$, donde n es el número de vectores en el espacio de entrada, $\omega \in \mathbb{R}^D$ es un vector ortogonal al hiperplano denominado vector de pesos y $b \in \mathbb{R}$, define el sesgo o umbral de decisión [45] [46].

Las MSV, utilizando optimización, buscan entre todos los hiperplanos separadores aquel que maximice la distancia de separación entre los conjuntos $(x_i, 1)$ y $(x_j, -1)$, con $i \neq j$, o expresado de otra manera, entre (x_i, y_i) y (x_j, y_j) con $y_i \neq y_j$ y $x_i \neq x_j$.




Figura 11. Ilustración de un conjunto de observaciones no linealmente separables.

Por otro lado, fijado un hiperplano separador siempre es posible a los parámetros ω y b , reescalarlos de tal forma que:

$$\langle x_i, \omega \rangle + b \geq +1 \text{ para } y_i = +1 \quad (3)$$

$$\langle x_j, \omega \rangle + b \leq -1 \text{ para } y_j = -1 \quad (4)$$

De esta forma, la mínima separación entre los vectores y el hiperplano separador es la unidad como se observa en (3) y (4). Estas desigualdades se pueden expresar en una sola de la forma siguiente:

$$y_i(\langle x_i, \omega \rangle + b) - 1 \geq 0 \text{ con } 1 \leq i \leq n \quad (5)$$

Ahora el problema de encontrar el hiperplano equidistante a dos clases se reduce a encontrar la solución al siguiente problema de optimización con restricciones [46].

$$\begin{cases} \text{Maximizar } \frac{1}{\|\omega\|} \\ \text{Sujeto a } & y_i(x_i, \omega + b) - 1 \geq 0 \quad \text{con } 1 \leq i \leq n \end{cases} \quad (6)$$

También, se puede plantear el problema de optimización con restricciones, equivalente a la anterior [44–46], como sigue:

$$\begin{cases} \text{Minimizar } \frac{1}{2}\|\omega\|^2 \\ \text{Sujeto a } & y_i(x_i, \omega + b) - 1 \geq 0 \quad \text{con } 1 \leq i \leq n \end{cases} \quad (7)$$

2.6.5. Formulación dual de la MSV.

En ocasiones la solución de la MSV de margen máximo se expresa como combinación lineal de los vectores de aprendizaje obteniéndose la formulación dual que resuelve el problema original, evitando trabajar directamente con las desigualdades. Entonces, para resolver el problema de optimización se utilizan los multiplicadores de Lagrange. Así, la nueva función objetivo es:

$$L(\omega, b, \alpha) + \frac{1}{2}\|\omega\|^2 \sum_{i=1}^N \alpha_i(1 - y_i(x_i, \omega + b)) \quad (8)$$

Para resolver el problema original se maximiza la función $L(\omega, b, \alpha_i)$ respecto a las variables duales α_i , para que los gradientes de L con respecto a ω y b sean nulos.

Derivando (8), con respecto a las variables originales, se tiene:

$$\frac{\partial L(\omega, b, \alpha)}{\partial \omega} = 0 \Rightarrow \omega - \sum_{i=1}^N y_i \alpha_i x_i = 0 \Rightarrow \omega = \sum_{i=1}^N y_i \alpha_i x_i \quad (9)$$

$$\frac{\partial L(\omega, b, \alpha)}{\partial b} = 0 \Rightarrow \sum_{i=1}^N y_i \alpha_i = 0 \quad (10)$$

Sustituyendo las relaciones anteriores (9) y (10) en la función de Lagrange (8), se obtiene:

$$L(\omega, b, \alpha) = \frac{1}{2} \sum_{i,j=1}^N y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle - \sum_{i,j=1}^N y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle + \sum_{i,j=1}^N \alpha_i \quad (11)$$

Luego, la función objetivo dual (11) se expresa como:

$$L(\omega, b, \alpha) = \sum_{i,j=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle \quad (12)$$

Los vectores del conjunto de entrenamiento que proporcionan un multiplicador de Lagrange $\alpha_i \geq 0$ y que se encuentran en la frontera de decisión son los denominados vectores de soporte [45] [46].

2.6.6. Máquinas de soporte vectorial con margen máximo en el espacio de características.

Cuando el aprendizaje de los separadores no es lineal, se debe hacer una transformación no lineal del espacio de atributos de entrada (conjunto de observaciones) a un espacio de características de dimensión mucho mayor dotado de un producto escalar (espacio de Hilbert), donde las observaciones pueden ser separadas linealmente [46].

Sea una aplicación del conjunto de entradas X , en un espacio \mathfrak{F} (denominado espacio de características) dotado de un producto escalar, como se representa en:

$$\begin{cases} \Phi : \mathbb{R}^d \rightarrow \mathfrak{S} \\ x \rightarrow \Phi(x) \end{cases} \quad (13)$$

Ahora, en lugar de considerar el conjunto de vectores $\{x_1, x_2, \dots, x_n\}$ se consideran los vectores transformados: $\{\Phi_{(x_1)}, \Phi_{(x_2)}, \dots, \Phi_{(x_n)}\}$ [45] [46].

Si se plantea el problema de optimización original a estos nuevos vectores, se tiene que los mismos vectores forman parte de la solución del problema, solo a través del producto escalar definido en $\mathfrak{S} : \langle \Phi_{(x_i)}, \Phi_{(y_i)} \rangle$.

Para ciertos espacios de características y ciertas transformaciones, existe una forma muy efectiva de calcular el producto escalar usando las denominadas funciones núcleo.

Una función núcleo es una función $K : X \times X \rightarrow \mathbb{R}$ tal que $K(x_i, y) = \langle \Phi_{(x_i)}, \Phi_{(y_i)} \rangle$, donde Φ es una transformación de X en cierto espacio de Hilbert \mathfrak{S} .

Las funciones núcleo permiten trabajar eficientemente en el espacio de características, pues calculan el producto escalar de dos vectores. Como ahora se trabaja en el espacio de características dotado de un producto escalar, se aplican los razonamientos utilizados en las máquinas de soporte vectorial con margen máximo.

Es importante destacar que para garantizar el éxito de la aplicación de máquinas de soporte vectorial, la función núcleo seleccionada debe ser la adecuada, y esto va a depender del conocimiento que se tenga a priori del problema.

Existen varias funciones núcleo, siendo las más utilizadas en \mathbb{R}^d :

$$\text{Polinómica: } (\langle x, y \rangle + c)^d, \text{ con } c \in \mathbb{R} \text{ y } d \in \mathbb{N} \quad (14)$$

$$\text{Gaussiana: } \exp\left(\frac{-\|x-y\|^2}{\gamma}\right), \text{ con } \gamma > 0 \quad (15)$$

$$\text{Sigmoïdal: } \tanh s \langle x, y \rangle + r, \text{ con } s, r \in \mathbb{R} \quad (16)$$

$$\text{Multicuadrática inversa: } \frac{1}{\sqrt{\|x-y\|^2 + c^2}}, \text{ con } c \in \mathbb{R} \quad (17)$$

Lo relevante de usar funciones núcleo con MSV, es que el producto escalar se puede calcular implícitamente, sin conocer de manera explícita \mathfrak{S} ni la transformación Φ [47].

2.6.7. Máquinas de soporte vectorial con margen blando.

Cuando los ejemplos de aprendizaje (datos de entrada) no son separables ni en el espacio de entradas ni en el espacio de características, es decir, cuando no se logra encontrar una transformación de los datos (inducida por alguna función núcleo) que permita separarlos linealmente, o cuando no se puede encontrar un separador perfecto del conjunto de aprendizaje debido a que los datos presentan ruido (ejemplos mal etiquetados, con errores de medición, con comportamientos atípicos, inconsistencias, entre otros), se prefiere tener algunos elementos mal clasificados en lugar de enfocarse en todos los ejemplos de aprendizaje, ya que esto puede provocar soluciones sobreajustadas a los ejemplos y comprometer la generalización del clasificador. Ante estos casos, el problema de optimización no encuentra una solución, sin embargo, no es difícil ampliar las ideas del caso separable al caso no separable. Para esto se utilizan las máquinas de soporte vectorial con margen blando, que permiten trabajar con conjuntos de observaciones que no son linealmente separables y que presentan ruido. Estos modelos son más robustos que las máquinas de soporte vectorial con margen máximo. La idea principal, bajo el margen blando, es introducir variables ξ de holgura que hagan posible que las restricciones no se cumplan de manera estricta [46][47]. Con el vector de variables ξ de holgura se plantea un nuevo conjunto de restricciones:

$$\begin{cases} \langle x_i, \omega \rangle + b \geq +1 - \xi_i \text{ para } y_i = +1 \\ \langle x_j, \omega \rangle + b \leq -1 + \xi_j \text{ para } y_j = -1 \end{cases} \quad (18)$$

Donde $\xi \geq 0 \forall i = 1, \dots, n$

El vector de variables de holgura tiene la misma dimensión que los vectores del conjunto de datos. El mínimo valor que puede tener una variable de holgura es 0. Ya que en el caso no separable se cometen errores, en la función a optimizar se introduce un término de regulación que incluye una constante positiva C , dicho término depende de la variable ξ de holgura y controla la holgura del margen, conocido como margen blando. Esta constante debe ser fijada a priori por lo que es un parámetro de aprendizaje [46][47].

Habitualmente en las máquinas de soporte vectorial con margen blando, se introduce lo que se conoce como la norma 1 de las variables de holgura que tienen la ventaja de que ningún valor ξ_i , ni ninguno de sus correspondientes multiplicadores de Lagrange, aparecen en el problema dual. Por lo tanto, el problema de optimización que se plantea es:

$$\begin{cases} \min_{\omega \in \mathbb{R}^d} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i \\ \text{Sujeto a: } y_i(x_i, \omega + b) - 1 + \xi_i \geq 0, \forall i \text{ y } \xi_i \geq 0, \forall i \end{cases} \quad (19)$$

Si al problema de optimización expresado en (19), se le aplica la teoría de optimización con restricciones lineales, y usando funciones núcleo para permitir clasificadores no lineales, se obtiene el siguiente resultado:

$$\begin{cases} \max \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n y_i y_j \alpha_i \alpha_j K(x_i, X_j) \\ \text{Sujeto a } \sum_{i=1}^n y_i \alpha_i = 0 \text{ y } 0 \leq \alpha_i \leq C \end{cases} \quad (20)$$

Donde K es una función núcleo $K(x,y)$. En las MSV con margen blando los vectores soporte se dividen en: vectores de soporte normales ($\alpha_i \leq C$ y margen funcional 1) y vectores de soporte acotados ($\alpha_i = C$ y margen funcional menor que 1) [46].

2.6.8. Máquinas de soporte vectorial para multclasificación.

La clasificación en dos grupos es la más sencilla de las aplicaciones de las máquinas de soporte vectorial. Cuando se trabaja con problemas de clasificación reales, lo común es encontrarse con la necesidad de realizar clasificaciones en más de dos grupos, para esto se utilizan las máquinas de soporte de vectores para clasificación multiclase [47]

Una vez definida o diseñada una máquina de soporte vectorial o máquina de aprendizaje para clasificación binaria, se puede generalizar a N números de clases y viceversa, de N clases se puede llevar a clasificación binaria.

Se denomina máquina de soporte vectorial para clasificación multiclase a toda aquella arquitectura de máquina de aprendizaje que sea capaz de responder a cualquier cantidad de entradas de clasificación, es decir, N entradas diferentes.

Considerando al conjunto de posibles etiquetas o clases $y \in \{\theta_1, \theta_2, \dots, \theta_\ell\}$, donde: ℓ es mayor a 2 y no está definida ninguna relación de orden entre ellas, si Z es el conjunto de entrenamiento, y estando definidos los subconjuntos que determinan una partición de dicho conjunto, entonces:

$$Z_k = \{(x_i, y_i) \rightarrow \text{tales que } y_i = \theta_k\} \quad (21)$$

Se denota por n_k la cantidad de vectores de entrenamiento del conjunto Z_k , ($n = n_1, n_2, \dots, n_\ell$) donde cada n_i es el número de vectores de entrada para cada clase, de un total de ℓ clases, tal que: $(x_i, y_i) \in Z_k$, respectivamente, de donde se desprende que $\bigcup_{i \in I_k} \{(x_i, y_i)\} = Z_k$ [46].

Existen dos tipos de arquitecturas para utilizar la técnica de máquinas de so-

porte vectorial para clasificación multiclase:

- Máquinas de soporte vectorial biclasificadoras generalizadas: Se construye una función clasificadora global partiendo de un conjunto de funciones clasificadoras de tipo dicotómicas. Donde se van comparando por pares de observaciones y cuando se obtenga la probabilidad más alta, ese es el grupo al que pertenece la observación. Esto es, hay que realizar un conjunto de combinaciones de dos en dos, de la cantidad de grupos en que se desee clasificar. Estas máquinas también son conocidas como máquinas multclasificadoras 1vs 1 ó por pares.
- Máquinas de soporte vectorial multclasificadoras: Estas construyen una función de clasificación global considerando directamente a todas las clases a la vez.

Las MSV biclasificadoras generalizadas resuelven el problema de la clasificación multiclase, transformando las ℓ particiones del conjunto de entrenamiento en un nuevo conjunto de L biparticiones donde se construye la función clasificadora correspondiente, la cual que se conoce como esquema de descomposición, obteniendo f_1, f_2, \dots, f_ℓ clasificadores binarios, dicotómicos o biclasificadores. Mediante un esquema de reconstrucción se realiza la fusión de los biclasificadores $f_i, i = 1, 2, \dots, \ell$ con la intención de aportar como salida final, una de las, clases posibles [49].

Las máquinas de soporte vectorial más utilizadas para multclasificación son:

- Máquinas de soporte vectorial una versus una: son aquellas donde cada función parcial clasificadora f_{ij} enfrenta los vectores de la clase θ_i con los de la clase θ_j sin tener en cuenta las clases restantes.
- Máquinas de soporte vectorial una versus el resto ó una contra todas: son aquellas donde cada función parcial clasificadora f_i enfrenta los vectores de la clase θ_i a los vectores de las clases restantes.

2.7. Evaluación de clasificadores.

El objetivo del aprendizaje supervisado es obtener una función de decisión f , en un espacio de hipótesis H , para ello, los algoritmos de aprendizaje emplean una muestra S formadas por patrones de una distribución D . Dado que es posible inducir un conjunto bastante grande de hipótesis desde un único patrón, mediante

la utilización de diversas técnicas de aprendizaje, es necesario establecer metodologías de calidad para evaluar las hipótesis y una de esas es la validación cruzada [46][47].

2.7.1. Evaluación mediante validación cruzada.

Un mecanismo que permite reducir la dependencia del resultado del experimento en modo en el cual se realiza la partición, es la validación cruzada (*cross validation*), Este método que se ilustra en la Figura 12, consiste en dividir un conjunto de evidencias (patrones) en k subconjuntos disjuntos de tamaño similar. Entonces, se utiliza un conjunto para aprender una hipótesis (optimizar una función de decisión), y los subconjuntos restantes se emplean para calcular error de validación [46][47].

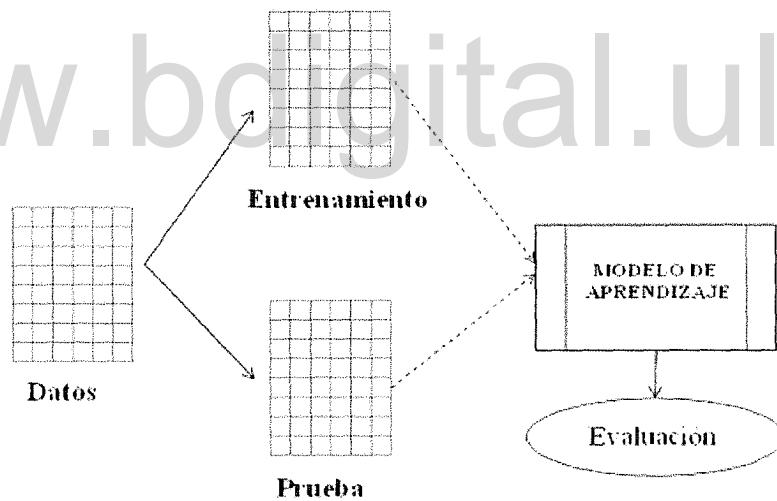


Figura 12. Evaluación mediante validación cruzada.

Algunas de las medidas de calidad que se pueden utilizar para evaluar los clasificadores se resumen en la matriz de confusión, la cual es una matriz de $l \times l$ con l el número de clases, donde en la diagonal de la matriz se encuentran el número de instancias bien clasificadas en cada clase, y en el resto de las celdas las mal clasificadas y en qué clase.

Otras medidas de calidad para evaluar clasificadores son:

- Tasa de verdaderos positivos (*True Positive Rate*).
Es la proporción de elementos que están clasificados dentro de la clase ℓ , de entre todos los elementos que realmente son de la clase ℓ . En la matriz de confusión es el elemento diagonal dividido por la suma de todos los elementos de la fila.
- Tasa de falsos positivos (*False Positive Rate*).
Es la proporción de elementos que han sido clasificados dentro de la clase ℓ , pero pertenecen a una clase diferente. En la matriz de confusión es la suma de la columna de la clase ℓ menos el elemento diagonal menos la suma de las filas del resto de las clases.
- Precisión.
Es la proporción de elementos que realmente tienen clase ℓ de entre todos los elementos que se han clasificado dentro de la clase ℓ . En la matriz de confusión es el elemento diagonal dividido por la suma de la columna en la que se encuentra [49].

CAPÍTULO III METODOLOGÍA

"Se alcanza el éxito convirtiendo cada paso en una meta y cada meta en un paso." C. C. Cortéz.

3.1. Identificación del tipo de investigación desarrollada.

La investigación desarrollada fue aplicada y consistió en el desarrollo de un clasificador basado en máquinas de soporte vectorial para complejos QRS de los electrocardiogramas. El desarrollo se fundamentó en:

- Revisión de los aspectos teóricos y técnicos aplicados al reconocimiento de patrones y clasificación de señales ECG.
- Revisión de los aspectos teóricos de las máquinas de soporte vectorial.
- Selección y descripción de los datos a utilizar.
- Desarrollo de los algoritmos de obtención de patrones para la clasificación de complejos QRS de señales electrocardiográficas.
- Validación de la obtención de patrones para la clasificación de señales ECG.
- Revisión de software para implementar máquinas de soporte vectorial.
- Implementar algoritmos para la clasificación de complejos QRS de señales electrocardiográficas.
- Validación de los algoritmos de clasificación.

3.2. Revisión de los aspectos teóricos y técnicos del reconocimiento de patrones y señales ECG.

En esta fase se utilizaron técnicas de investigación documental, a través de libros, revistas y recursos en línea que permitieron evaluar y documentar el funcionamiento del sistema cardiovascular, las técnicas para la caracterización del ritmo

cardíaco normal y diferentes episodios de arritmias; técnicas para la obtención de patrones y técnicas basadas en máquinas de soporte vectorial para clasificación tal como fue expuesto en el Capítulo II.

3.3. Descripción de los datos.

Se utilizó la base de datos de arritmias cardíacas del Instituto Tecnológico de Massachusetts (*Massachusetts Institute of Technology, MIT*) y El Hospital Beth Israel de Boston, (*Beth Israel Deaconess Medical Center, BIH*), la cual es de distribución gratuita y cuenta con 48 registros electrocardiográficos digitalizados a una frecuencia de 360 muestras por segundo, con 11 bits de resolución, un rango de 10 mV. y de aproximadamente 30 min. de duración cada uno. Estos registros provienen de 25 hombres entre 32 y 89 años y 22 mujeres entre 23 y 89 años, con las características que se observan en la Tabla 2.

Tabla 2. Descripción de los registros de la base de datos de arritmias del MIT-BIH.

Código del registro	Sexo del paciente *	Edad paciente (Años)	Derivaciones registradas	Medicación
100	M	69	MLII V5	Aldomet, Inderal
101	F	75	MLII V1	Diapress
102	F	84	V5 V2	Digoxin
103	M	-	MLII V2	Diapres, Xyloprim
104	F	66	V5 V2	Digoxin, Pronestyl
105	F	73	MLII V1	Digoxin, Nitropaste
106	F	24	MLII V1	Indera
107	M	63	MLII V1	Digoxin
108	F	87	MLII V1	Digoxin, Quinaglute
109	M7	64	MLII V1	Quinidine
111	F	47	MLII V1	Digoxin, Lasix
112	M	54	MLII V1	Digoxin, Pronestyl
113	F	24	MLII V1	Ninguno
114	F	72	MLII V5	Digoxin
115	F	39	MLII V1	Ninguno
116	M	68	MLII V1	Ninguno
117	M	69	MLII V2	Ninguno
118	M	69	MLII V1	Digoxin, Norpace
119	F	51	MLII V1	Pronestyl
220	F	87	MLII V1	Digoxin
222	F	84	MLII V1	Digoxin, Quinidine
223	M	73	MLII V1	Ninguno

* F = Femenino, M = Masculino

Cada ECG almacenado en la base de datos de arritmias cardíacas del MIT-BIH tiene asociado tres archivos: uno de datos (.dat), que almacena el registro de la señal ECG en formato binario 212, uno de cabecera (.hea) que identifica el individuo del cual proviene la señal y uno de anotaciones (.atr) donde se identifica el tipo de cada complejos QRS, como se observa en la Figura 13.

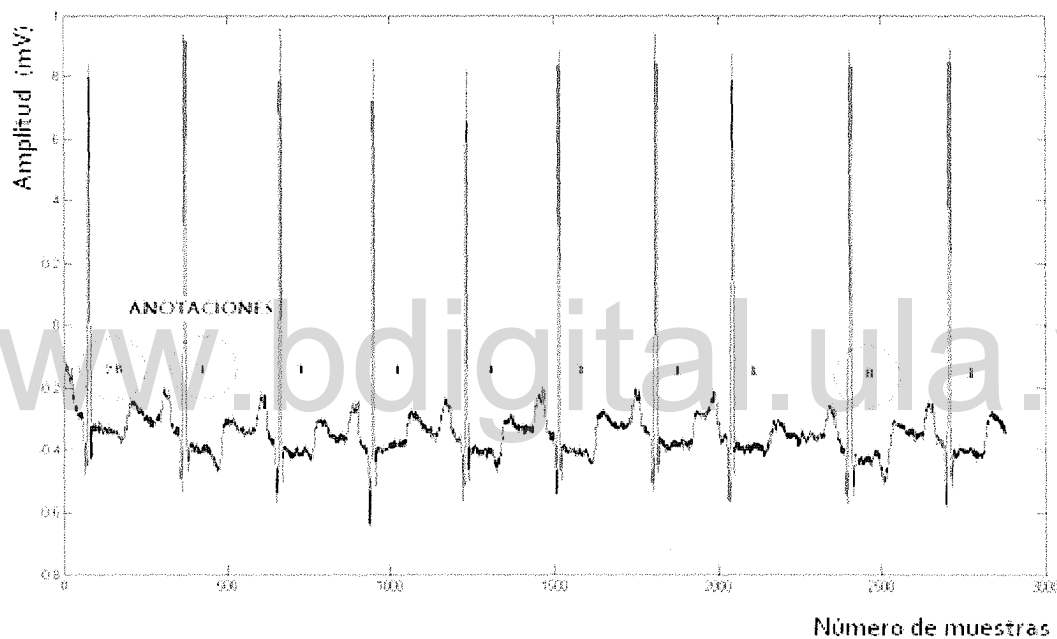


Figura 13. Trazo de un registro ECG proveniente del la base de datos MIT-BIH con sus respectivas anotaciones.

Esta base de datos tiene un total de 110.149 complejos QRS, en el Tabla 3 se observa la contabilización de los tipos de latidos: Normal (1), Latido bloqueo de la rama izquierda (2), Latido bloqueo de la rama derecha(3), Contracción ventricular prematura PVC (5), Latido PACED (12), Contracción atrial prematura APC (8), cambio de calidad de la señal (14) y cambio de ritmo (28), estos tipos de complejos QRS son los que en mayor cantidad están presentes en la base de datos.

Tabla 3. Número de complejos PQRST según algunos tipos por cada registro.

Código del Registro	Tipo de Latido								TOTAL
	1	2	3	5	8	12	14	28	
100	2239	0	0	1	33	0	0	1	2274
101	1860	0	0	0	3	0	4	1	1868
102	99	0	0	4	0	2028	0	5	2136
103	2082	0	0	0	2	0	6	1	2091
104	163	0	0	2	0	1380	37	45	1627
105	2526	0	0	41	0	0	88	1	2656
106	1507	0	0	520	0	0	30	41	2098
107	0	0	0	59	0	2078	2	1	2140
108	1583	0	0	16	3	0	38	1	1641
109	0	2492	0	38	0	0	2	1	2533
111	0	2123	0	1	0	0	8	1	2133
112	2345	0	0	0	2	0	10	1	2358
113	1789	0	0	0	0	0	0	1	1790
114	1820	0	0	43	10	0	7	3	1883
115	1953	0	0	0	0	0	2	1	1956
116	2110	0	0	108	1	0	8	0	2227
117	1412	0	0	426	0	0	4	99	1941
118	0	0	2166	16	96	0	12	1	2291
119	1543	0	0	444	0	0	4	103	2094
121	1861	0	0	1	1	0	12	1	1876
122	2476	0	0	0	0	0	0	1	2477
123	1396	0	0	2	0	0	0	1	1399
124	0	0	1396	46	2	0	2	13	1459
200	1606	0	0	783	25	0	40	139	2593
201	1625	0	0	198	30	0	4	35	1892
202	2061	0	0	19	36	0	0	8	2124
203	2529	0	0	444	0	0	57	45	3075
205	2386	0	0	67	3	0	2	13	2471
207	0	1457	86	105	107	0	15	24	1794
208	1586	0	0	992	0	0	24	53	2655
209	2432	0	0	1	345	0	17	15	2810
210	2423	0	0	194	0	0	17	17	2651
212	923	0	1825	0	0	0	13	1	2762
213	2635	0	0	220	25	0	0	43	2923
214	0	2003	0	256	0	0	4	25	2288
215	2953	0	0	151	3	0	26	5	3138
217	244	0	0	162	0	1542	4	67	2019
219	2082	0	0	64	7	0	0	21	2174
220	1954	0	0	0	94	0	4	17	2069
223	1860	0	0	390	0	0	12	23	2285
TOTAL	73112	8075	7124	7486	2501	7028	605	1373	

*(Calculados utilizando el archivo de anotaciones y la nomenclatura que se muestra en la Tabla 1.)

3.4. Obtención de patrones para la clasificación de señales ECG.

Existen diferentes características del complejo QRS del electrocardiograma que son utilizadas como patrones para su clasificación, la obtención de estos patrones es la parametrización. En esta etapa de la investigación se utilizaron, diversos algoritmos para la obtención de los intervalos R-R, duración del complejo QRS, amplitud de los segmentos QR, RS, entre otros, los cuales son indicadores del comportamiento de la señal en el dominio del tiempo-frecuencia.

3.5. Validación de la obtención de patrones para la clasificación de señales ECG.

Para realizar la evaluación de un algoritmo de clasificación de ECG es necesario contar con una colección de casos y mediciones electrocardiográficas de referencia de inicio y fin de las ondas y los segmentos o intervalos mencionados, con los que puedan realizarse las comparaciones necesarias y determinar si el programa a evaluar brinda resultados dentro de rangos aceptables [52], para esto se contó con los archivos de anotaciones del MIT-BIH.

3.6. Diseño y desarrollo de los algoritmos para la clasificación de complejos QRS normales y anormales de señales electrocardiográficas.

Para el diseño e implementación del algoritmo de clasificación se utilizó una metodología, basada en módulos, que se muestra en la Figura 14.

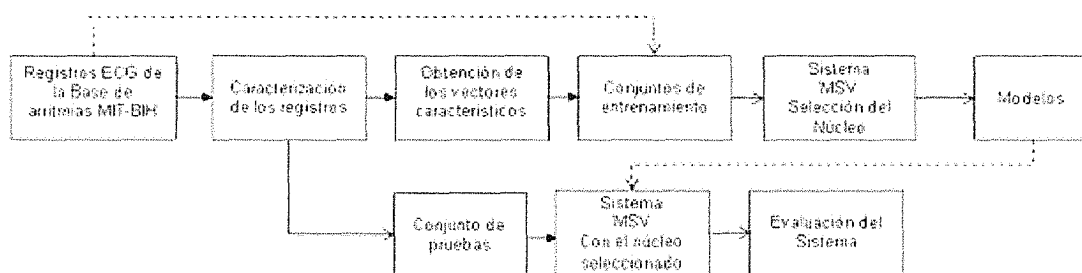


Figura 14. Metodología para la implementación de un sistema de clasificación basado en máquinas de soporte vectorial.

3.7. Validación y evaluación de los algoritmos de clasificación.

En esta etapa del proyecto se realizó una validación de cada uno de los módulos implementados, se calculó la efectividad del algoritmo de clasificación utilizando validación cruzada y se comparó con el resultado de otras técnicas similares como: análisis lineal discriminante, comparación morfológica, entre otras metodologías documentadas en el estado del arte.

www.bdigital.ula.ve

CAPÍTULO IV

ADQUISICIÓN DE DATOS Y PRUEBAS REALIZADAS

”¿Quién decide cuando los médicos no se ponen de acuerdo?” Anónimo.

4.1. Carga de los datos de la base de datos del MIT-BIH.

Los registros de la base de datos del MIT-BIH están en el formato binario 212, el cual no es un formato portable, para hacerlo portable a otras aplicaciones o lenguajes de programación, se diseñó una función programada en MATLAB®(Carga.m, Anexo A), basada en un conjunto de algoritmos de distribución gratuita proporcionadas por el MIT y conocidos como *Physio Toolkit* [53]. Carga.m lee los registros y los transforma a dos tipos de archivos uno .txt y el otro .mat, el primer es un tipo de archivo plano que permite procesarlos y graficarlos con otras aplicaciones, y el segundo es un archivo de datos utilizados por el lenguaje de programación MATLAB®. En la Tabla 4 se especifican las entradas y salidas de la función Carga.m y en la Figura 15 se observa el diagrama de flujo de dicha función.

Tabla 4. Descripción de variables de entrada y salida de la función Carga.m.

VARIABLE		FUNCIÓN
ENTRADA	Ruta	Especifica la ruta donde están almacenados los archivos .dat, .atr, .hea
	Registro	Especifica el nombre del registro a cargar
	Tventana	Especifica el número de muestras que se quieren cargar. Por defecto 650000, 30 min.
	Ventana	Especifica cual rango de valores se desea cargar. Es múltiplo del tamaño total del registro/Tventana
	Derivación	Especifica cuál de las 2 derivaciones posibles se va a cargar.
SALIDA	ECG.valores	Es un vector que contiene los valores del registro ECG
	ECG.anotaciones	Es un vector que contiene las anotaciones de cada complejo QRS registrado en ECG.valores
	ECG.TIEMPO	Es un vector que contiene los tiempos de registro en s. del vector ECG.valores

4.2. Obtención de los parámetros (patrones) de los registros ECG.

Los parámetros utilizados para la identificación y clasificación de arritmias cardíacas, pueden ser muy diversos, debido a la naturaleza de la señal y a la técnica automatizada implementada para calcularlos.

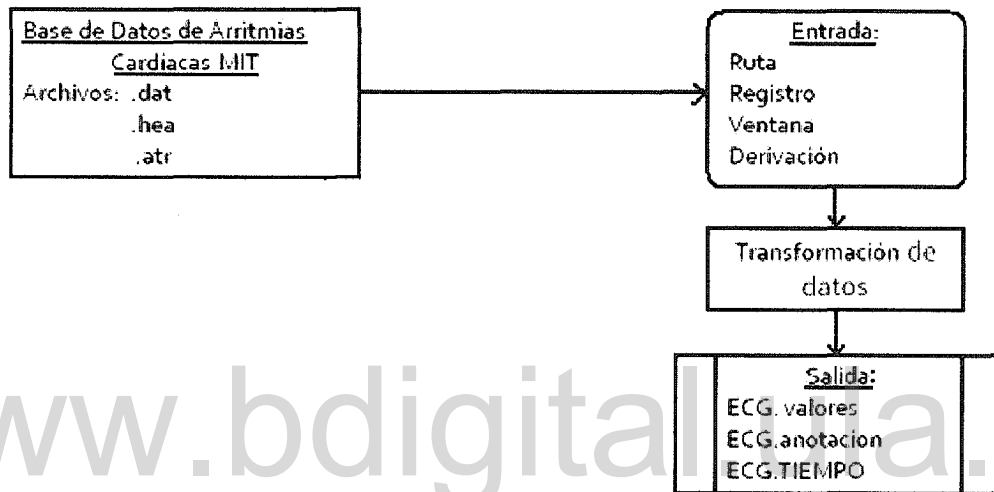


Figura 15. Diagrama de flujo de la función Carga.m

Los patrones utilizados, en este trabajo se seleccionaron fundamentados en las recomendaciones de la Asociación Americana del Corazón (*American Heart Association*), los cuales se establecen según la morfología de la señal, la presencia, amplitud, forma y separación de las distintas ondas, donde las amplitudes están asociadas a las células del miocardio y los tiempos están condicionados por las células nerviosas [54]. Los patrones seleccionados en milisegundos (ms, 10^3 s.) y milivoltios (mV, 10^3 V), se observan en la Figura 16:

- Duración de la onda P (DP en s).
- Intervalo PR. (PR en s).
- Duración del QRS medido hasta el punto J (QRS en s).
- Duración del intervalo QT (QT en s).
- Duración de la onda T (DT en s).

- Intervalo RR (RR en s).
- Amplitud de onda QR (AQR en mV).
- Amplitud de onda RS (ARS en mV).




Figura 16. Parámetros calculados para la caracterización de los complejos PQRST de un ECG.

Para la obtención de estos parámetros se realizó un pre-procesamiento de los registros ECG en tres etapas :

- Filtrado digital.
- Detección del complejo PQRST.
- Obtención de los parámetros de los complejos PQRS.

4.2.1. Filtrado Digital

Para la clasificación de los latidos que componen el ECG, se tomaron en cuenta los posibles ruidos e interferencias de adquisición producidas por la red de suministro eléctrico, equipos electrónicos y el contacto de los electrodos presentes en las señales, las cuales pueden dificultar la identificación y obtención de los parámetros en dominio de la frecuencia o el tiempo. En la Figura 17 se observa el espectro de frecuencia de los complejos QRS en un estudio realizado por Thakor, Webster y Tompkins en 1983 [55], donde se puede apreciar que el rango de frecuencia de los complejos QRS está aproximadamente en un rango de 4 a 20 Hz.

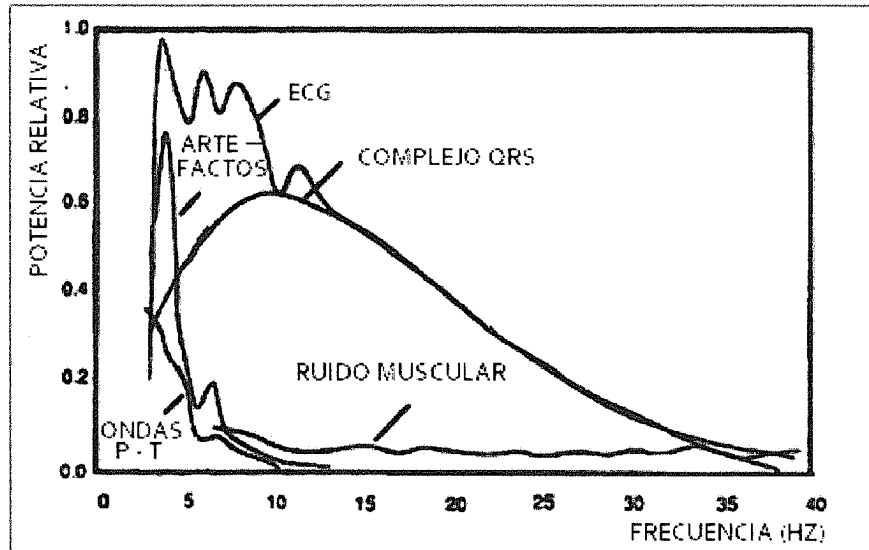


Figura 17. Rangos de frecuencia de los complejos QRS [55]

Para eliminar el ruido o perturbaciones en la señal ECG se programó una función (filtro.m, Anexo B), basada en el algoritmo desarrollado por Pan y Tompkins [56], donde se contruye un filtro pasa banda a través de un filtro pasa bajo en cascada con un filtro pasa alto, con un ancho de banda entre 4Hz y 15 Hz. En la Figura 18 se observa el diagrama de flujo de esta función, y en la Tabla 5 las variables involucradas.

Tabla 5. Descripción de las variables de la función filtro.m

VARIABLE		FUNCIÓN
ENTRADA	ECG.valores	Es el vector de señal de entrada que será filtrado
PROCESO	a	Es la salida del filtro pasa bajo de frecuencia de corte $F_o = 15$ Hz
SALIDA	b	Almacena el vector de salida, luego de aplicar al vector a, el filtro pasa alto.

Filtro pasa banda: éste se diseñó utilizando un filtro pasa bajo de primer orden con frecuencia de corte $F_o = 15$ Hz, con la función de transferencia que se muestra en (22) y un filtro pasa alto de primer orden con frecuencia de corte $F_o = 4$ Hz y función de transferencia (23).

$$y(i) = 2y(i - 1) - y(i - 2) + x(i) - 2x(i - 6) + x(i - 12) \quad (22)$$

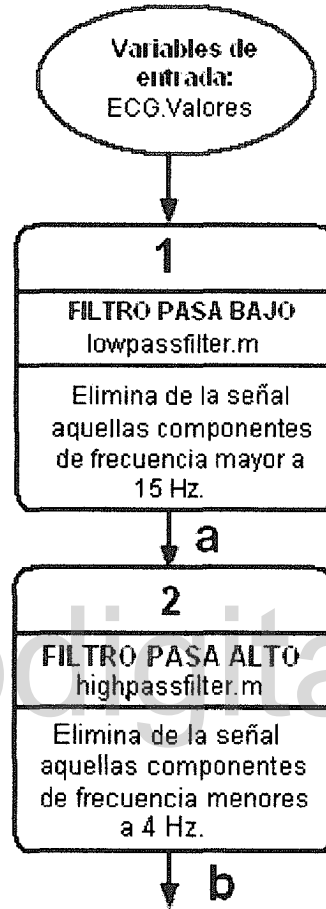


Figura 18. Diagrama de flujo de la función filtro.m

$$y(i) = 2y(i - 1) - \frac{1}{32}x(i) + x(i - 16) - x(i - 17) + \frac{1}{32}x(i - 32) \quad (23)$$

Donde $y(i)$ es la señal filtrada y $x(i)$ es la señal sin filtrar, provenientes del registro ECG .

En la Figura 19(a) se puede observar la atenuación que sufre una señal de prueba senoidal, con una frecuencia entre 1 y 15 Hz, muestreada a 360 muestras por segundo, luego de aplicarle el filtro pasa bajo y en la Figura 19(b), la misma señal de prueba pero al aplicarle el filtro pasa alto.

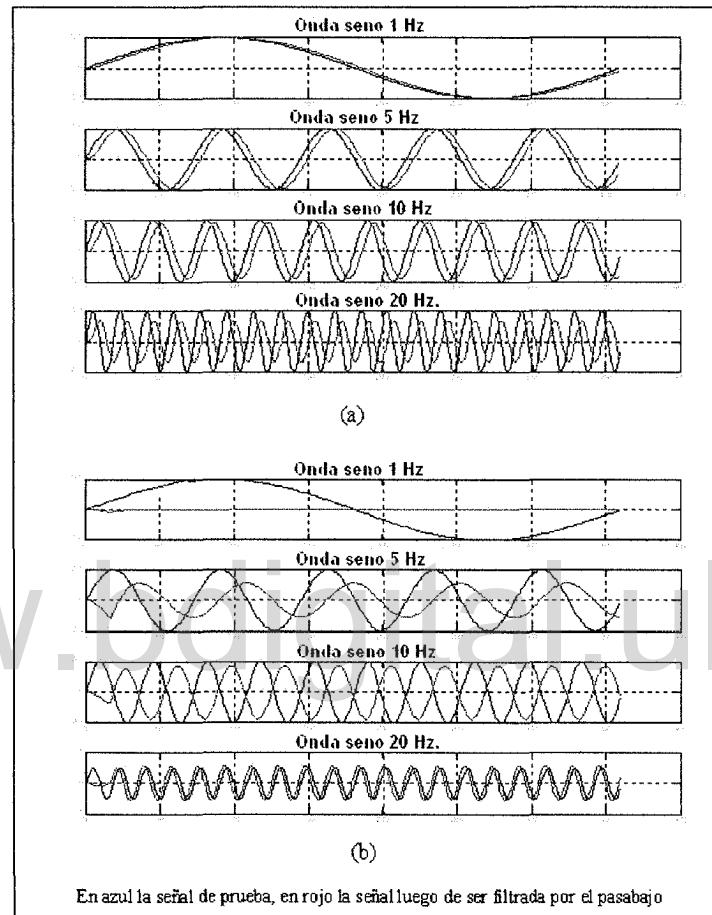


Figura 19. Prueba de la función filtro.m con una señal senoidal.

4.2.2. Detección del complejo PQRST.

A la señal filtrada se le aplica un filtro derivador (24), con el fin de enfatizar la pendiente de los picos R del complejo QRS.

$$y(i) = \frac{1}{8}(2x(i) + x(i - 1) - x(i - 3) - 2x(n - 4)) \quad (24)$$

En la Figura 20, se observa la señal obtenida del filtro derivador, donde se encuentran resaltadas las pendientes de las curvas más prominentes de la señal ECG. Dado que la derivación acentúa las altas frecuencias y atenúa las bajas, por lo tanto resalta las altas pendientes por las cuales generalmente se distinguen los QRS dentro de la señal de ECG.

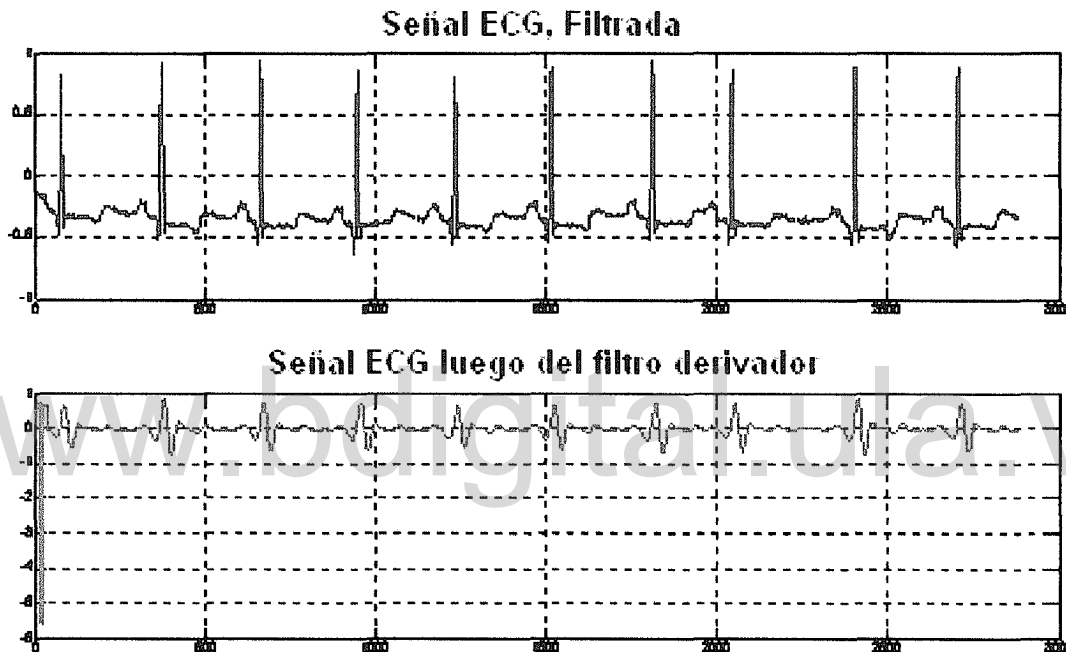


Figura 20. Señal ECG luego de aplicado el filtro derivador.

Debido a que en la señal ECG pueden estar presentes picos anómalos, que no coinciden con el pico R, se implementa una función integradora (Vintegradora.m, Anexo C), con la función en diferencias que se muestra en (25):

$$y(nT) = \frac{1}{N}[x(nT - (N - 1)T) + x(nT - (N - 2)T) + \dots + x(nT)] \quad (25)$$

Donde N es el tamaño de la ventana.

Dado que un QRS normal tiene una duración entre 60 ms y 100 ms, se toma como valor predefinido para N , 85 ms., que para la base utilizada son 30 muestras.

En la Figura 21, se puede observar la entrada (en rojo) y salida (en verde) de la ventana integradora.

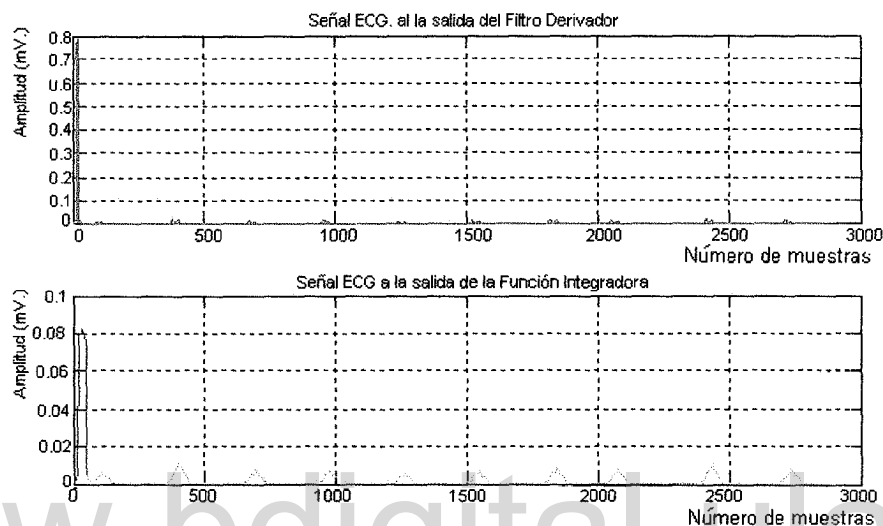


Figura 21. Señal de entrada y salida de la función integradora.

A la señal que se obtiene de la ventana integradora se le aplica una función de detección de picos R. En la Figura 22, se observan los picos identificados en la señal.

4.2.3. Obtención de patrones del complejo PQRST.

Para la obtención de los parámetros: DP, PR, QRS, QT, DT, RR, AQR y ARS, se desarrolló un algoritmo semi-automático basado en umbrales. Este algoritmo, a partir de la ubicación de los picos R, aísla los complejos PQRST y calcula la duración de los intervalos y amplitud de las ondas, como se observa en la Figura 23.

Para la evaluación del algoritmo de obtención de patrones y estudiar su fiabilidad en la parametrización de complejos QRS, se tomó como registro de referencia el codificado como 103 en la base de datos de arritmias cardíacas del MIT-BIH y se compararon los resultados con los obtenidos por Yun-Chi Yeh *et al.* [57], quienes utilizaron una técnica, donde obtienen puntos máximos por bandas de 50 muestras. En el Tabla 6 se puede apreciar que existe muy poca diferencia entre los valores obtenidos por ambos algoritmos.




Figura 22. Detección de los picos R en un complejo QRS.

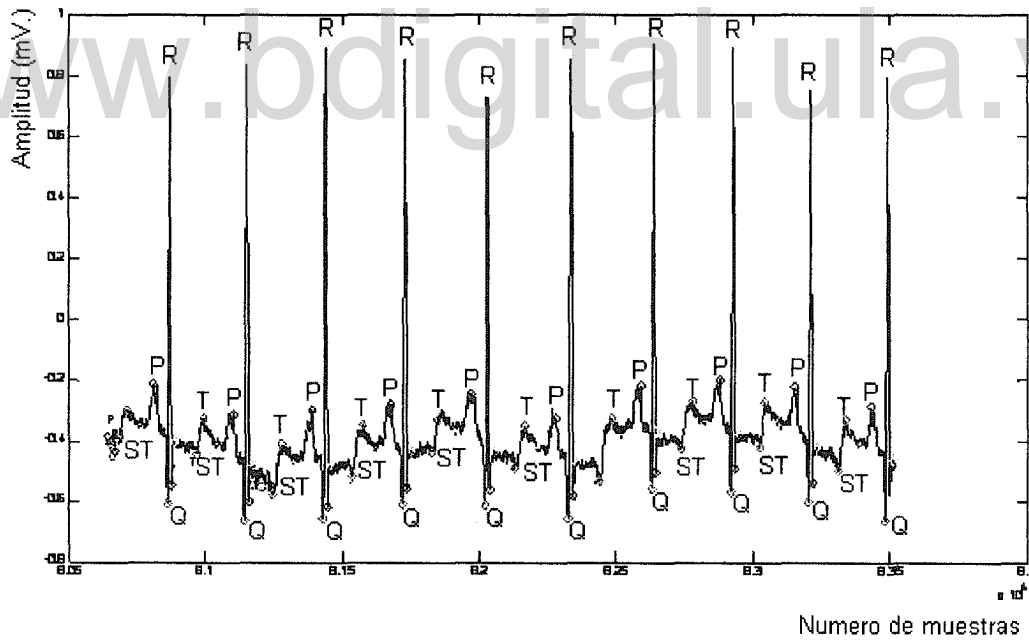


Figura 23. Patrones detectados en un complejo PQRST

Tabla 6. Tabla resumen de los parámetros de complejos QRS normales del

registro 103, de la base de datos de arritmias cardíacas del MIT-BIH.

Número de muestras: 2083	Estadístico	QRS	RR	AQR	ARS
Algoritmo de Yun-Chi Yeh <i>et al.</i>	Mínimo	44	8.828	2.125	2.050
	Máximo	64	1.145	2.625	2.625
Desarrollado en este trabajo	Mínimo	44	8.900	2.125	2.000
	Máximo	64	1.100	2.625	2.500
Unidad		ms.		mV.	

Del total de registros de la base de datos se caracterizaron morfológicamente los registros 100, 103, 107, 112, 116, 122, 202 y 209 de pacientes hombres y 101, 102, 105, 106, 113, 115, 123 y 220 de mujeres. Estos registros presentan la mayor cantidad de arritmias cardíacas y se obtuvieron 34. 611 vectores de 8 parámetros (DP, PR, QRS, QT, DT, RR, AQR, ARS) cada uno. Se descarta el primer latido en todos los registros debido a que no es posible calcular la duración de la onda P y el intervalo RR en estos. En la Tabla 7 se observa la distribución por tipo y número de los latidos parametrizados en los 16 registros utilizados de la base de datos.

Tabla 7. Distribución de los tipos de complejos QRS, que fueron parametrizados en 16 registros de la base de datos de Arritmias Cardíacas del MIT-BIH.

TIPO DE LATIDO	NÚMERO
1 (Normal)	28.829
4 (Aberración Latido prematuro Auricular)	25
5 (Contracción Ventricular Prematura, PVC)	755
6 (Fusión Latido Normal y Ventricular)	1
8 (Contracción Atrial prematura, APC)	516
12 (Latido PACED)	4.106
13 (Desconocido identificable)	7
14 (Cambio de calidad de la señal)	170
16 (QRS aislados con artefacto)	51
28 (Cambio de ritmo)	95
38 (FUSION ritmo y latido normal)	56
TOTAL	34.611

4.2.3.1. Patrones de complejos QRS normales.

En el Tabla 8, se pueden apreciar los estadísticos Media (\bar{x}), Desviación Estándar (δ) y Coeficiente de variación (C.V) de los 28.829 complejos QRS normales, en los que se refleja lo siguiente:

- Los valores de duración del intervalo QRS para los registros 100, 101, 103, 113, 115, 116, 209 y 220 se encuentran entre 67 ms y 120 ms que son considerados como valores normales [57][58], y en el caso de los registros 102, 105, 106, 112, 122, 123 y 202 sus valores se encuentran entre 134 ms y 253 ms; los cuales son considerados QRS muy extensos.
- Los valores de los intervalos RR se encuentran en promedio entre 606 y 1857 ms. y reflejan el tiempo entre los picos R de los complejos QRS. Estos intervalos permiten calcular el ritmo cardíaco o número de pulsaciones por minuto (p.p.m). Estos están en un rango promedio entre 50,54 y 99,01 p.p.m, los cuales según la documentación de la base de datos y especificaciones de electrocardiografía son considerados como normales [57][58].
- La duración del intervalo ST debe ser menor a 20 ms en los latidos cardíacos para ser considerados normales. Los valores calculados se encuentran en promedio entre 26 y 221 ms.
- Los coeficientes de variación (C.V) de los patrones por cada registro, son indicadores del porcentaje de variabilidad que está presente en los datos y para este caso son bajos para los patrones de un mismo registro.

Tabla 8. Resumen de los patrones QRS, ST, RR, de complejos QRS normales.

REGISTRO	SEXO	EDAD	VARIABLE	ESTADÍSTICOS		
				\bar{x}	δ	C.V (%)
100	M	69	QRS (ms)	69	12	16,741
102	F	84		98,4	33	9,243
101	F	75		104	15	14,356
103	M	-		67	6	8,418
105	F	73		160	31	19,210
106	F	24		253	25	10,016
112	M	54		134	16	12,327
113	F	24		110	10	9,457
115	F	39		123	13	10,272
116	M	68		112	31	27,459
122	M	51		136	10	7,318
123	F	63		135	10	7,444
209	M	62		79	15	18,790
220	F	87		104	12	11,278

... Continuación Tabla 8

REGISTRO	SEXO	VARIABLE	ESTADÍSTICOS		
			\bar{x}	δ	C.V (%)
100	M	RR (ms)	794	41	5,143
100	M		794	41	5,143
101	F		965	71	7,318
102	F		809	62	7,698
103	M		867	46	5,255
105	F		716	57	7,909
107	M		850	30	3,522
112	M		711	21	2,986
113	F		998	109	10,968
115	F		923	84	9,127
116	M		756	84	11,160
122	M		729	40	5,498
123	F		1187	118	9,903
209	M		606	74	12,276
220	F		884	84	9,556
100	M	ST (ms)	221	30	13,52
101	F		108	23	21,054
102	F		73	23	32,189
103	M		103	12	12,004
105	F		123	27	21,814
106	F		26	13	49,127
112	M		165	15	8,852
113	F		102	20	19,544
115	F		175	17	9,437
116	M		65	19	29,679
122	M	73	24	33,293	
123	F	134	12	8,653	
209	M	45	17	38,237	
220	F	110	21	19,502	

4.2.3.2. Patrones de complejos QRS con episodios de contracción ventricular prematura.

En la Tabla 9 se muestran los valores promedios (\bar{x}) de duración, desviación estándar (δ) y coeficiente de variación de 755 patrones de complejos QRS con episodios de contracción ventricular prematura (PVC) presentes en los registros: 100, 102, 105, 106, 107, 116, 123, 202, 209. Sin embargo sólo se describe el comportamiento de los registros 105, 106, 107, 116 y 202, ya que en los otros registros el número de episodios de PVC que aparece es menor a 5.

Tabla 9. Resumen de los patrones QRS y DP de complejos QRS con PVC.

REGISTRO	SEXO	VARIABLE	ESTADÍSTICOS		
			\bar{x}	δ	C.V (%)
105	F	QRS (ms)	292	16	5,628
106	F		203	64	31,347
107	M		198	22	11,174
116	M		156	27	17,285
202	M		254	25	9,738
105	F	DP (ms)	1	25	52,469
106	F		19	62	38,904
107	M		6	31	58,795
116	M		67	30	19,190
202	M		14	22	34,919

De la Tabla 9 se resume lo siguiente:

- La duración del Complejo QRS en latidos con contracción ventricular prematura es mayor a 120 ms, lo que se evidencia en la muestra, donde el rango promedio se encuentra entre 156 y 292 ms.
- En los episodios de contracción ventricular prematura, la onda P puede no aparecer o estar solapada con el complejo QRS, es decir, debe tener tiempos de duración muy cortos, en este caso el promedio es menor a 67 ms.
- Para todos los patrones se observaron índices de variación de moderados a altos reflejando lo heterogéneo que son los parámetros que caracterizan los complejos QRS de cada registro.

4.2.3.3. Patrones de complejos QRS, con episodios de contracción auricular prematura.

Fueron parametrizados 516 complejos QRS con APC, registrados en los archivos 100, 101, 103, 116, 112, 202, 209 y 220. Se hace la descripción sólo con los registros 100, 102, 209 y 220, ya que éstos representan el 98,44 % de los latidos APC parametrizados.

En el Tabla 10 se observan los estadísticos calculados para los patrones PR y RR, los cuales presentan las características morfológicas más relevantes de este tipo de arritmias, siendo éstas:

- Intervalos PR largos de más de 120 ms de duración, lo cual se refleja en toda la muestra.
- Ritmo cardíaco irregular e intervalos RR largos. El ritmo cardíaco oscila entre 55 y 105 p.p.m.
- El coeficiente de variabilidad en casi todos los casos es pequeño lo que indica que existe poca dispersión en los datos.

Tabla 10. Resumen de los patrones de complejos QRS con contracción auricular prematura.

REGISTRO	SEXO	VARIABLE	ESTADÍSTICOS		
			\bar{x}	δ	C.V (%)
100	M	PR (ms)	942	150	15,911
202	M		207	33	15,721
209	M		1157	132	17,960
220	F		974	153	15,686
100	M	RR (ms)	817	90	11,042
202	M		1084	356	32,853
209	M		569	127	22,254
220	F		856	170	19,848

4.2.3.4. Patrones de latidos PACED.

En el Tabla 11 se muestran los estadísticos media, desviación estándar y coeficiente de variación de los patrones para los 4.106 complejos QRS de latidos PACED provenientes de los registros 102 y 107. Se observa que los patrones tienen una variabilidad baja en cada registro y estos complejos poseen segmentos QRS largos e intervalos RR considerados normales.

Tabla 11. Resumen de los patrones de complejos QRS PACED

REGISTRO	SEXO	VARIABLE	ESTADÍSTICOS		
			\bar{x}	δ	C.V (%)
102	F	QRS (ms)	236	45	19,069
107	M		280	30	10,798
102	F	RR (ms)	828	33	3,953
107	M		859	82	9,523

4.3. Diseño de un clasificador de latidos cardíacos basado en máquinas de soporte vectorial.

La implementación del clasificador se basó en la arquitectura que se muestra en la Figura 24, la cual está dividido en dos etapas: la de entrenamiento donde se programaron diversos clasificadores con máquinas de soporte vectorial utilizando diversas funciones *kernel* y parámetros asociados a estas funciones, los cuales fueron evaluados utilizando diversos casos de prueba para seleccionar el mejor clasificador.

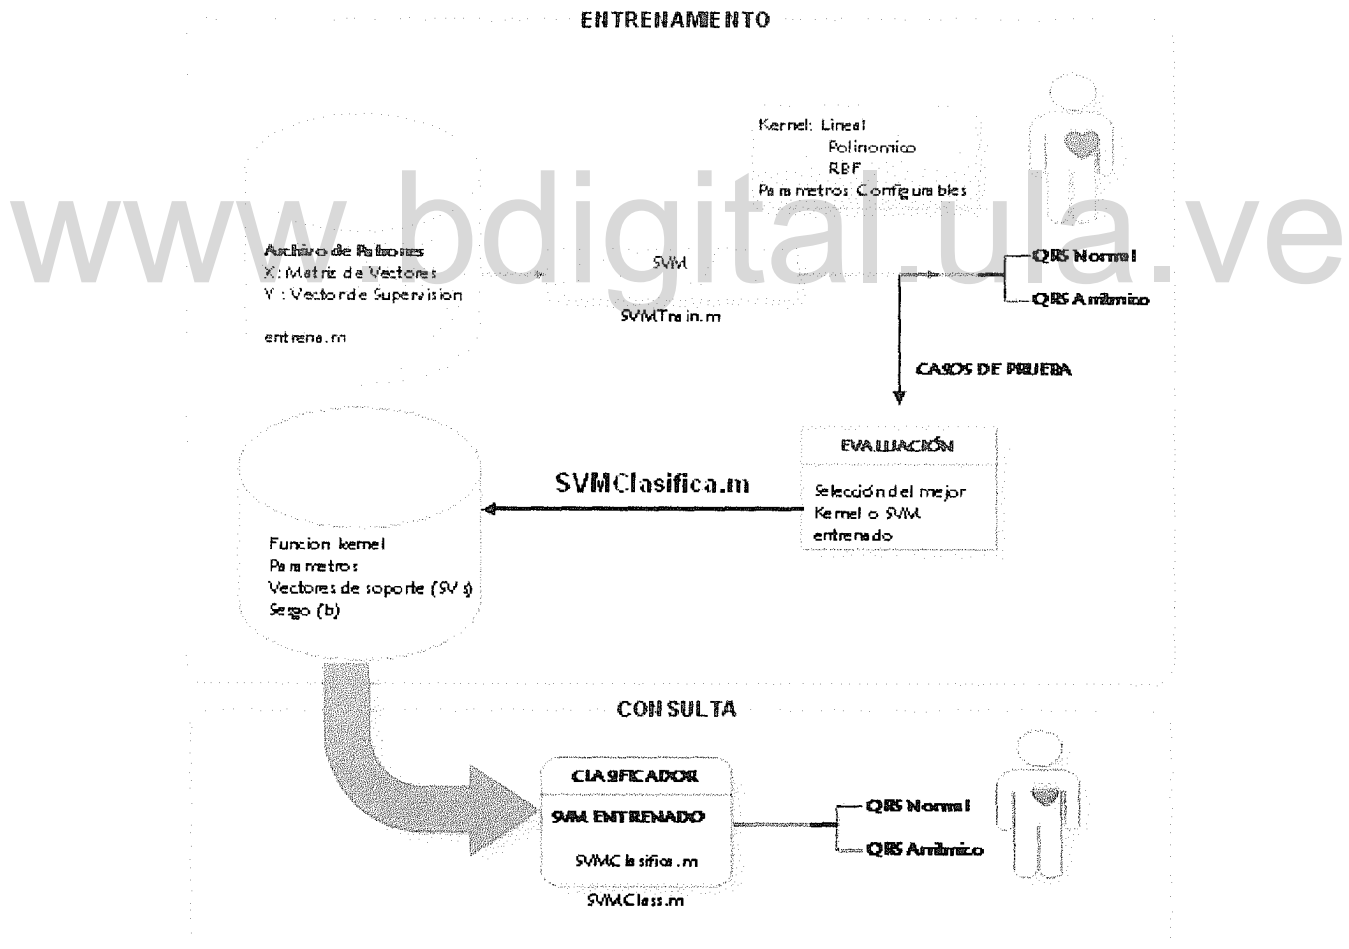


Figura 24. Arquitectura del clasificador de complejos QRS basado en MSV.

La segunda etapa, o etapa de consulta, consistió en utilizar el clasificador seleccionado en la primera etapa para evaluar el tipo de latido cardíaco representado por cualquier vector de entrada que caracteriza a un complejo QRS.

4.3.1. Etapa de entranamiento, construcción del clasificador.

Para la construcción se utilizó MATLAB® y los componentes LIBSVM (Librería de máquinas de soporte vectorial) de la organización de métodos basados en *kernel* y máquinas de soporte vectorial, Kernel-Machine.org [59]. Se entrenaron máquinas de soporte vectorial con funciones *kernel* Lineal, Polinomial y Gaussiana de base Radial (RBF).

Para el entrenamiento del clasificador se desarrolló la función clasifica.m (Anexo D), cuyo diagrama de flujo se presenta en la Figura 25, y en la Tabla 12 se muestra el formato y función de las variables de entrada y salida.

Tabla 12. Descripción de las variables de la función clasifica.m.

	VARIABLE	FUNCIÓN
ENTRADA	Muestras(X)	Matriz [M,N] con los vectores de entrada. M los parámetros y N el número de patrones
	Etiquetas (Y)	Vector de tamaño N que contienen las etiquetas definidas de $1, \dots, \ell$, donde ℓ , es el número de clases
	Kernel (0-3)	Define el tipo de <i>Kernel</i> , 0: Lineal, 1: Polinomial, 2: RBF
	Parámetros	Dependen del <i>Kernel</i> seleccionado, y γ el grado en el caso de <i>Kernel</i> polinomial
SALIDA	AlphaY	αY vector con los multiplicadores de Lagrange $\neq 0$
	nSV	Es un vector fila de tamaño ℓ que almacena el número de vectores de soporte en cada clase.
	nLabels	Es un vector fila de tamaño ℓ que almacena el número de etiquetas de cada clase
	SVs	Es una matriz con los vectores de soporte [M,X], donde X es el número total de vectores de soporte para las ℓ clases. Estos vectores son aquellos cuyos coeficientes α no son cero
	Parámetros	Es un vector que almacena los parámetros utilizados para el entrenamiento
	Bias	Es el sesgo entre cada 2 clases

La matriz de los vectores de entrada (X) y el vector de supervisión (Y) tienen la

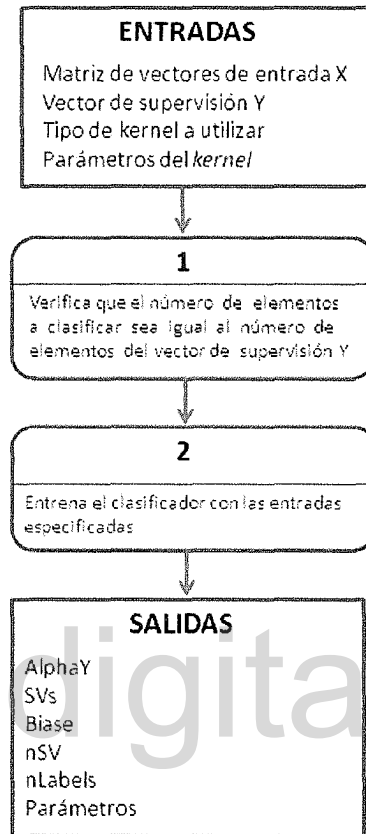


Figura 25. Diagrama de flujo de la función clasifica.m.

forma:

$$X = \begin{bmatrix} DP_1 & \dots & \dots & \dots & DP_N \\ PR_1 & \dots & \dots & \dots & PR_N \\ QRS_1 & \dots & \dots & \dots & QRS_N \\ ST_1 & \dots & \dots & \dots & ST_N \\ DT_1 & \dots & \dots & \dots & DT_N \\ RR_1 & \dots & \dots & \dots & RR_N \\ AQR_1 & \dots & \dots & \dots & AQR_N \\ ARS_1 & \dots & \dots & \dots & ARS_N \end{bmatrix}$$

Donde N es el número de vectores de entrenamiento.

$$y = [1_1 \cdots 1_{\ell_1} 2_1 \cdots 2_{\ell_1} L_1 \cdots L_{\ell_1}]$$

Donde: $1, 2, \dots, L$, son las clases representadas por números enteros

l_1, l_2, \dots, l_ℓ , es el número de vectores pertenecientes a cada clase.

ℓ , es el número total de clases y su sumatoria debe ser igual a N .

Posteriormente se utilizó la función `mexSVMtrain`, desarrollada por Chang C., y Chih J. en el año 2006 [60], la cual formula el diseño de los clasificadores de máquinas de soporte vectorial a partir de la ecuación (20), donde se realiza el planteamiento dual de la forma siguiente:

$$\begin{cases} \min_{\alpha} \frac{1}{2} \alpha^T Q \alpha + e^T \alpha \\ \text{Sujeto } a y^T \alpha = 0 \text{ y } 0 \leq \alpha_i \leq C \end{cases} \quad (26)$$

Donde:

e es un vector de unos.

$C > 0$ es el límite superior de los multiplicadores de la Lagrange.

Q es una matriz semidefinida positiva $\ell \times \ell$, $Q_{ij} \equiv y_i y_j K(x_i, x_j)$, ℓ = número de clases.

K , es la función núcleo o *Kernel*, $K \equiv \Phi(x_i^T, x_j)$.

En la Figura 26 se observa el diagrama de flujo de la función entrenamiento `mexSVMtrain.m`, la cual comienza con la verificación de los parámetros de entrada de la función *kernel*, los cuales si no se proporcionan se le asignan valores predefinidos (Tabla 13).

Tabla 13. Valores preestablecidos por defecto para las variables de entrada en el proceso de entrenamiento.

VARIABLE	VALOR PREDEFINIDO
<i>kernel</i>	2 (<i>kernel</i> RBF)
grado (En caso de <i>kernel</i> tipo 1 Polinomial)	3
γ	1

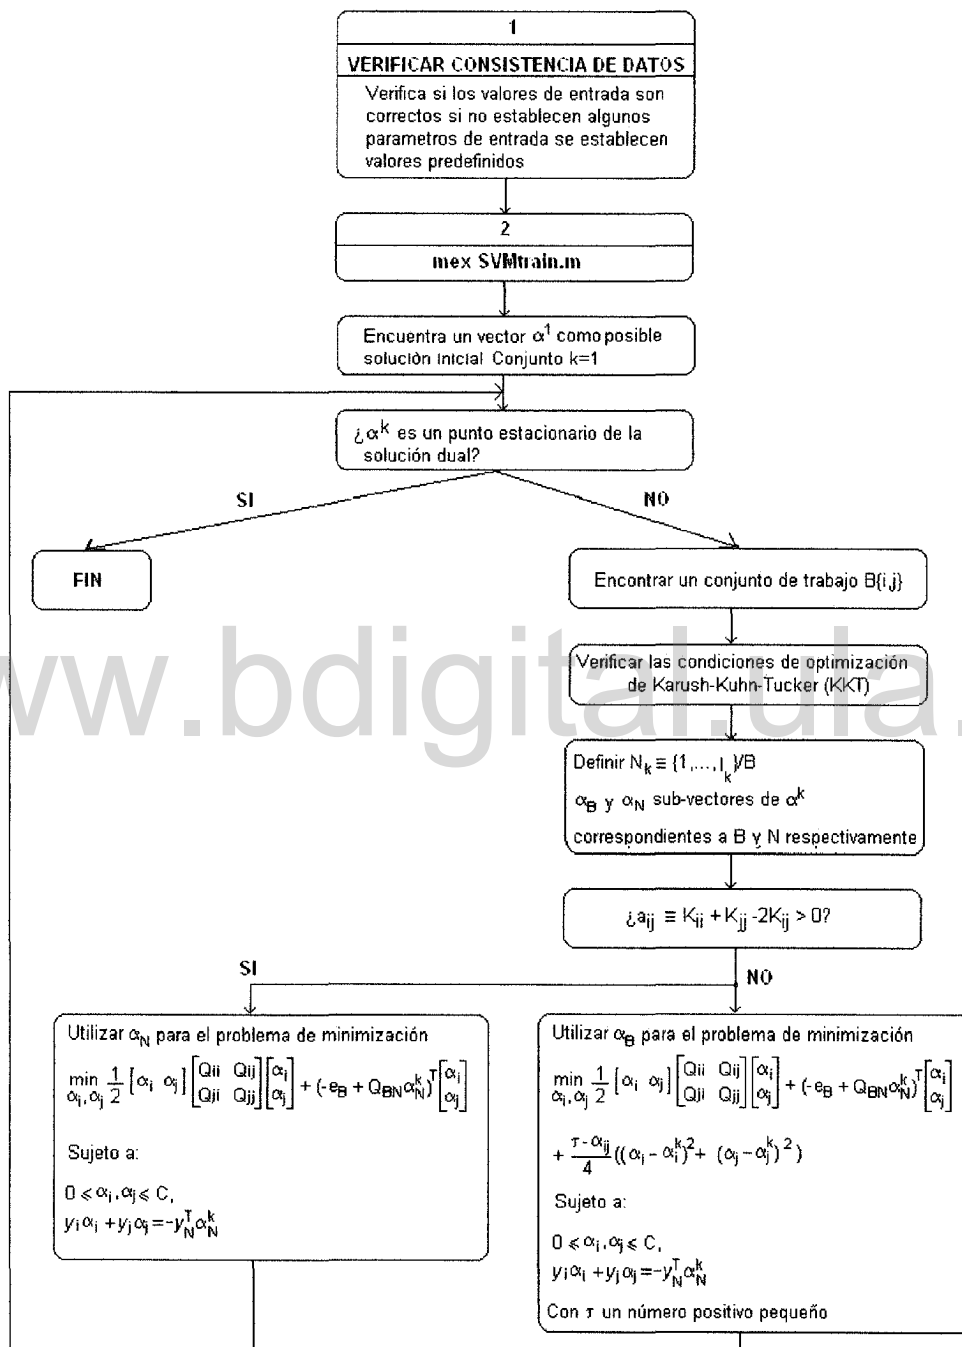


Figura 26. Diagrama de flujo de la función mexSVMtrain.m.

Una vez que se obtienen los multiplicadores α de Lagrange, se crea la matriz SVs, con los vectores de soporte, los cuales son aquellos α distintos de 0 para cada clase. Se realiza la multclasificación con la técnica 1 Vs 1 ó por pares, calculando en cada caso el sesgo de la función de decisión definida en (2). Estos parámetros que conforman la máquina de soporte vectorial entrenada fueron almacenadas en un archivo de datos denominado SVMClasificador.

Para el proceso de entrenamiento y validación de los clasificadores se trabajó con 34.611 patrones y para ésto se diseñaron 2 casos de prueba, utilizando validación cruzada:

1. Clasificación binaria de latidos normales con un tipo de arritmia, de un mismo paciente.
2. Clasificación multiclase, latidos normales, APC, PVC y PACED de diferentes pacientes.

4.3.2. Evaluación del clasificador.

Para la evaluación del clasificador se establecieron como criterio, los utilizados por los dos casos de prueba, en cada uno de ellos se tomaron como medidas de calidad las utilizadas en [57][58]:

- Tasa de clasificación negativa (TCN), es la relación de los QRS clasificados como normales:

$$TCN = \frac{VN}{VN + FN} \quad (27)$$

Donde:

VN: Verdaderos Negativos, número de vectores de entrada normales que fueron bien clasificados.

FN: Falsos Negativos, número de vectores de patrones de entrada arrítmicos que fueron clasificados como normales.

- Tasa de clasificación positiva (TCP), es la relación de los QRS arrítmicos bien clasificados:

$$TCP = \frac{VP}{VP + FP} \quad (28)$$

Donde:

VP: Verdaderos Positivos, número de patrones de entrada de una clase en particular de arritmia que fueron bien clasificados.

FP: Falsos Positivos, número de vectores de patrones de entrada normales que fueron clasificados como arritmias.

- Sensibilidad (Se): es la proporción de complejos QRS de una clase específica de arritmias bien clasificada.

$$Se = \frac{VP}{VP + FN} \quad (29)$$

www.bdigital.ula.ve

- Especificidad (Ep): Es la proporción de complejos QRS de la clase normal clasificados como normales siendo normales.

$$Ep = \frac{VN}{VN + FP} \quad (30)$$

- Exactitud (E): es el porcentaje de concordancia entre el total de vectores de entrada bien clasificados en todas las clases y el total de vectores de entrada para el proceso de clasificación.

$$E = \frac{VP + VN}{VP + VN + FP + FN} \quad (31)$$

Para realizar la evaluación y realizar el cálculo de TCN, TCP, Se, Ep y E, se diseñó la función prueba.m (Anexo E). En el Tabla 14 se muestran las variables de entrada y salida involucradas. Para esta función se utilizó la librería mexSVM-Class diseñada por Junshui y Zhao en el 2002 [61], la cual implementa el algoritmo de máquinas de soporte vectorial para múlticlasificación 1-1, que utiliza $\ell(\ell - 1)/2$ clasificadores binarios, donde ℓ es el número de clases y calcula la matriz de confusión en la que se contabiliza el número de elementos por cada clase que fueron bien o mal clasificados.

Tabla 14. Descripción de las variables de la función prueba.m.

VARIABLE		FUNCION
ENTRADA	AlphaY	αY vector con los multiplicadores de Lagrange $\neq 0$
	nSV	Es un vector fila de tamaño ℓ que almacena el número de vectores de soporte en cada clase.
	nLabels	Es un vector fila de tamaño ℓ que almacena el número de etiquetas de cada clase
	SVs	Es una matriz con los vectores de soporte $[M, X]$, donde X es el número total de vectores de soporte para las ℓ clases. Estos vectores son aquellos cuyos coeficientes α no son cero
	Parámetros	Es un vector que almacena los parámetros γ , grado, entre otros utilizados para el entrenamiento
	Biase	Es el sesgo entre cada 2 clases
SALIDA	ConfMatrix	Matriz de confusión
	Ns	Número de muestras en cada clase

4.3.3. Entrenamiento del primer caso de prueba.

En el Tabla 15 se muestran el número de vectores de entrada de cada tipo de de complejo QRS por registro, utilizados para entrenar varios clasificadores binarios por cada código de registro (paciente), donde la clase 1 la conformaron los QRS de tipo normal y la clase 2 por aquellos que presentan alguna patología. Estos patrones fueron seleccionados de forma aleatoria.

El número de vectores de soporte de cada clase, el sesgo y los parámetros asignados a cada función *kernel* utilizada en la etapa de entrenamiento se muestran en la Tabla 16. Donde destaca que la función *kernel* que utiliza, en el proceso de clasificación, menos vectores de soporte es la polinomial.

Tabla 15. Patrones de entrenamiento utilizados para el primer caso de prueba.

CÓDIGO DE REGISTRO	NORMALES	PVCs	APCs	PACED	TOTAL
100	1100	0	15	0	1115
105	550	13	0	0	563
106	750	250	0	0	1000
116	1050	50	0	0	1100
209	1200	0	150	0	1350
220	950	0	50	0	1000
TOTAL	5600	313	215	0	6128

Tabla 16. Resultados del entrenamiento en el primer caso de prueba.

REGISTRO	KERNEL	VECTORES DE SOPORTE			SESGO
		TOTAL	CLASE 1	CLASE 2	
100	Lincal	32	17	15	-0,4736
	Polinomial G=20	18	12	6	-0,5939
	Polinomial G=30	14	12	4	-0,9958
	RBF $\gamma = 20$	50	39	11	-0,8563
	RBF $\gamma = 30$	63	51	12	-0,8362
105	Lincal	26	14	12	-0,5227
	Polinomial G=20	7	5	2	-0,6836
	Polinomial G=30	6	5	1	-0,8164
	RBF $\gamma = 20$	45	35	10	-0,5167
	RBF $\gamma = 30$	60	49	11	-0,6539
106	Lincal	4	2	2	-1,6531
	Polinomial G=20	5	4	1	-1,0030
	Polinomial G=30	6	55	1	-1,1020
	RBF $\gamma = 20$	148	53	95	0,4535
	RBF $\gamma = 30$	192	68	124	0,4286
116	Lincal	103	53	50	1,3603
	Polinomial G=20	85	42	43	0,3324
	Polinomial G=30	80	41	39	0,4233
	RBF $\gamma = 20$	94	52	42	-0,2267
	RBF $\gamma = 30$	78	40	38	-0,5542
209	Lincal	220	120	100	-,8064
	Polinomial G=20	190	100	90	-1,2013
	Polinomial G=30	134	80	54	0,8049
	RBF $\gamma = 20$	90	45	45	0,7780
	RBF $\gamma = 30$	93	48	45	-0,8188
220	Lincal	114	70	44	-1,0046
	Polinomial G=20	88	48	40	0,4546
	Polinomial G=30	90	50	40	-0,9967
	RBF $\gamma = 20$	99	59	40	-0,8893
	RBF $\gamma = 30$	122	62	50	-0,7895

4.3.4. Evaluación del primer caso de pruebas.

Para evaluar el rendimiento de los clasificadores en el primer caso de pruebas, se realizaron dos tipos de consulta a los modelos generados: la primera utilizando los mismos datos empleados para el entrenamiento y la segunda utilizando datos distintos, seleccionados de forma aleatoria, con la distribución que se muestra en la Tabla 17.

En el Tabla 18, se pueden apreciar las medidas de evaluación de los clasificadores generados. Se observa que los clasificadores que ofrecen menor tasa de clasificación positiva son los de *kernel* lineal para vectores de QRS normales y con APC provenientes de los registros 100, 209, 220, donde en todos los casos ofrece 0 % de capacidad para la clasificación de arritmias. Por otra parte, el *kernel* polinómico con grado > 20 y el RBF con $\gamma > 20$, ofrecen una tasa de clasificación positiva entre 83 y 100 %.

Tabla 17. Patrones utilizados para consulta y evaluación el primer caso de prueba.

CÓDIGO DE REGISTRO	NORMALES	PVCs	APCs	PACED	TOTAL
100	1000	0	13	0	1013
105	600	13	0	0	613
106	700	460	0	0	1100
116	100	60	0	0	160
209	1150	0	150	0	1300
220	900	0	50	0	950
TOTAL	4450	473	213	0	5136

El comportamiento de los clasificadores con *kernel* lineal para los complejos QRS con APC (registros 100, 209 y 220) es deficiente, ya que la tasa de clasificación positiva es 0 % para todos los casos, lo cual quiere decir que no se logra clasificar ningún complejo con APC, a pesar que la tasa de clasificación negativa es 100 %, es decir se logran clasificar todos los latidos normales. En la Figura 27 se observa que los vectores de complejos QRS con APC se solapan sobre los vectores de complejos QRS normales siendo linealmente no separables, es por esto que ofrecen mejor rendimiento para este caso de clasificación binaria (APC - normales), las funciones *kernel* polinomial y RBF.

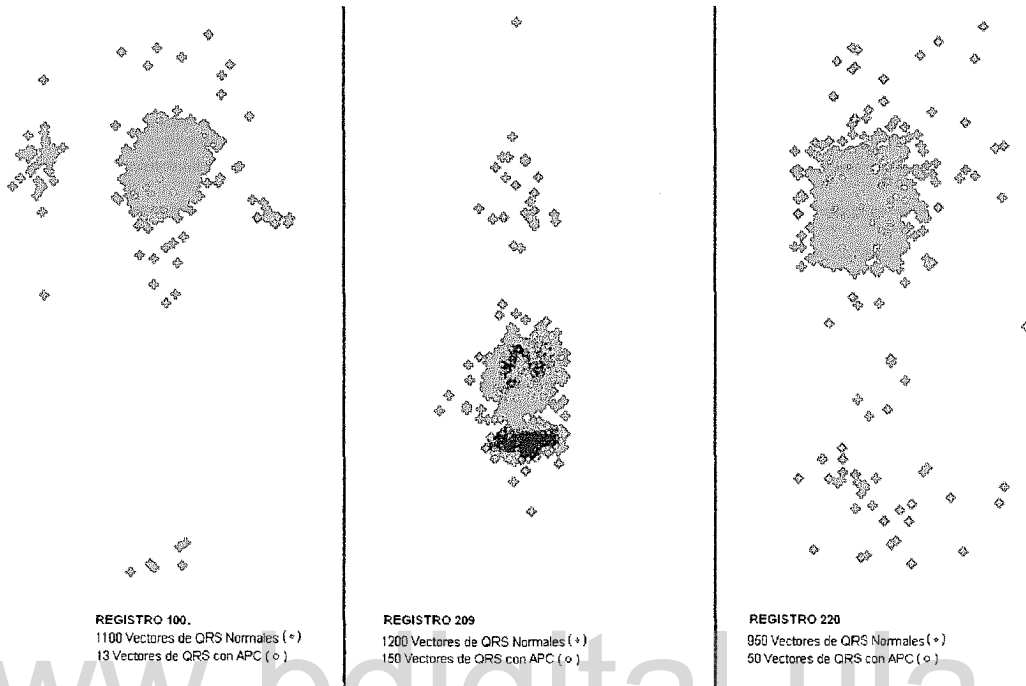


Figura 27. Vectores de complejos QRS normales y con APC de los registros 100,209 y 220.

En el caso de la discriminación de latidos PVC y normales (registros 105, 106, 116) ofrecen el mejor rendimiento de todos los modelos generados, con una tasa de clasificación positiva entre el 99 y 100 % con función *kernel* polinómica de grado > 20 y RBF con $\gamma > 20$.

Tabla 18. Medidas de evaluación de los clasificadores entrenados en el primer caso de prueba.

REGISTRO	KERNEL	Medidas de evaluación datos de entrenamiento		Medidas de evaluación datos de prueba	
		TCN	TCP	TCN	TCP
100	Lincal	100	0	100	0
	Polinomial G=20	98,68	83,33	100	100
	Polinomial G=30	98,68	83,33	100	100
	RBF $\gamma = 20$	99,74	83,33	99,91	73,33
	RBF $\gamma = 30$	99,74	99,69	99,91	86,67
105	Lincal	100	100	100	100
	Polinomial G=20	100	100	100	100
	Polinomial G=30	100	100	100	100
	RBF $\gamma = 20$	100	100	10	100
	RBF $\gamma = 30$	100	100	100	100
106	Lincal	0	99,62	100	100
	Polinomial G=20	100	100	92,94	99,62
	Polinomial G=30	100	100	100	100
	RBF $\gamma = 20$	100	100	44,74	100
	RBF $\gamma = 30$	100	100	99,87	97,74
116	Lincal	100	100	100	100
	Polinomial G=20	100	100	100	100
	Polinomial G=30	100	100	100	100
	RBF $\gamma = 20$	100	100	100	100
	RBF $\gamma = 30$	100	100	100	100
209	Lincal	99,43	0	100	0
	Polinomial G=20	100	100	100	100
	Polinomial G=30	100	100	100	100
	RBF $\gamma = 20$	100	100	100	100
	RBF $\gamma = 30$	100	100	100	100
220	Lincal	92,62	0	100	0
	Polinomial G=20	100	100	100	100
	Polinomial G=30	100	100	100	100
	RBF $\gamma = 20$	100	100	100	100
	RBF $\gamma = 30$	100	100	100	100

4.3.5. Entrenamiento del segundo caso de prueba.

En este caso se generaron multclasificadores con funciones *kernel*: lineal, polinómica y RBF. Fueron entrenados con los patrones que se muestran en el Tabla 19, que representan el 50% de los tipos de latidos parametrizados en cada uno de los 16 registros, seleccionados y ordenados de forma aleatoria, de manera que en cada grupo de datos tanto para entrenamiento como para validación existieran patrones de entrada de todos los registros.

Tabla 19. Patrones utilizados en el segundo caso de prueba.

TIPO DE QRS	NÚMERO DE VECTORES UTILIZADOS PARA EL ENTRENAMIENTO
Normal (Tipo 1)	14415
PVC (Tipo 5)	377
APC (Tipo 8)	258
PACED (Tipo 12)	2053
TOTAL	17.103

En el Tabla 20 se resumen los parámetros de los clasificadores generados, donde se aprecia que los valores de sesgo más bajos entre las MSV binarias para cada clase son menores en los construidos con la función *kernel* de base radial gaussiana.

Tabla 20. Resultados del entrenamiento en el segundo caso de prueba.

FUNCIÓN	No. DE VECTORES DE SOPORTE					SESGO (ω)
	TOTAL	NORMAL	PACED	APC	PVC	
Lincal	1011	487	260	200	64	-4,7 1,0 -4,1 2,8 -1,1 -2,4
Polinomial G=2	513	248	68	173	24	-2,3 1,9 -1,6 1,6 -0,2 -1,4
Polinomial G=3	426	210	30	176	10	-1,8 1,2 -1,5 1,1 -1,2 -1,3
RBF $\gamma = 2$	524	255	58	167	44	-0,3 -0,9 -0,3 -0,2 0,1 0,3
RBF $\gamma = 3$	512	252	57	159	44	-0,3 -0,9 -0,3 -0,1 -0,1 0,2

En el Tabla 21 se muestra el resultado de la evaluación de los clasificadores, para los cuales se utilizaron el mismo número de vectores de entrada, pero un grupo diferente que para el entrenamiento. Se observa que los clasificadores generados ofrecen una tasa de clasificación negativa (QRS normales) sobre el 99 % y tasa de clasificación positiva para latidos PACED sobre el 99 %, con funciones *kernel* polinomial y RBF. Para el caso de latidos PVC la tasa de clasificación está entre 97 y 99 %, para las mismas funciones *kernel*. Sin embargo, el porcentaje de clasificación de latidos APC es bajo, oscila entre 50 y 60 % aproximadamente.

Tabla 21. Resumen de la evaluación del segundo caso de prueba.

FUNCIÓN KERNEL	MEDIDAS DE EVALUACIÓN (%) DATOS DE ENTRENAMIENTO				MEDIDAS DE EVALUACIÓN (%) DATOS DE CONSULTA			
	TCN	TCP PACED	TCP APC	TCP PVC	TCN	TCP PACED	TCP APC	TCP PVC
	Lincal	99,60	98,05	34,58	91,24	99,30	98,00	34,30
Polinomial G=2	99,54	99,72	53,74	98,45	99,50	99,50	50,18	98,00
Polinomial G=3	99,52	99,89	55,14	99,48	99,50	99,50	50,12	99,50
RBF $\gamma = 2$	99,72	99,89	56,54	95,36	99,50	99,80	55,50	97,00
RBF $\gamma = 3$	99,72	99,89	60,75	99,48	99,50	99,80	60,75	99,50

4.3.6. Selección de la función *kernel*.

Tomando como medidas de evaluación preliminares las tasas de acierto para la clasificación de complejos QRS normales, APC, PVC y PACED, obtenidas con los valores calculados en los dos casos de pruebas utilizando validación cruzada, se evidencia la capacidad de los clasificadores para generalizar sus resultados, no sólo en el caso binario sino también en multclasificación, lo que implica que ofrecen buen rendimiento para la clasificación de complejos QRS pertenecientes a un mismo paciente y también son eficientes para la clasificación de latidos cardíacos de diferentes pacientes sin que afecte el género.

En la Tabla 22 se muestran los valores de especificidad, sensibilidad y exactitud de los multclasificadores utilizados en el segundo caso de pruebas.

Tabla 22. Medidas de precisión de los clasificadores generados en el segundo caso de prueba.

FUNCIÓN <i>KERNEL</i>	MEDIDAS DE EVALUACIÓN (%).					EXACTITUD
	NÚMERO DE VECTORES DE ENTRADA 17.703					
	Ep NORMAL	Se PVC	Se APC	Se PACED	Se PROMEDIO	
Lineal	56,68	99,82	63	34,64	66,82	80,87
Polinomial G=2	67,43	99,96	99,99	99,99	99,73	87,86
Polinomial G=3	68,63	99,96	99,99	99,99	99,72	88,51
RBF $\gamma = 2$	67,41	99,96	99,99	99,99	99,85	87,88
RBF $\gamma = 3$	71,43	99,96	99,99	99,99	99,86	89,96

De la Tabla 22 se tiene que el mejor clasificador multiclase para los complejos QRS arrítmicos fue el que se implementó con la función *kernel* RBF con $\gamma \geq 2$, ya que la sensibilidad promedio de la clasificación está sobre el 99,85% , siendo muy eficiente para los complejos QRS tipo PACED, donde todos los vectores de entrada de esta clase fueron bien clasificados, al igual que los de la clase PVC en los cuales un 99,96% de los vectores de entrada de esta clase que se clasificaron correctamente.

Por otra parte, si se evalúa la eficiencia de los clasificadores para QRS normales, esta es baja, el mejor de los casos fue la del multclasificador con función *kernel* RBF con $\gamma \geq 2$, donde se obtuvo una especificidad del 71,43%. Como se

mostró en la Tabla 22, la tasa de clasificación de los latidos APC era baja, pero el porcentaje de fallos en la clasificación es: APC clasificados como normales, como se observa en las matrices de confusión de la Tabla 23, en consecuencia de los complejos QRS clasificados como normales sólo un 71,43% realmente los eran.

Tabla 23. Matrices de confusión obtenida de los multclasificadores optimizados en el segundo caso de pruebas

FUNCIÓN KERNEL	RBF $\gamma \geq 2$			
Matriz de confusión	NORMAL	PVC	APC	PACED
NORMAL	99,71	0,04	0,24	0
PVC	0,11	99,89	0	0
APC	43,46	0	56,54	0
PACED	4,64	0	0	95,36
FUNCIÓN KERNEL	RBF $\gamma \geq 3$			
Matriz de confusión	NORMAL	PVC	APC	PACED
NORMAL	99,71	0,04	0,24	0
PVC	0,11	99,89	0	0
APC	39,25	0	60,75	0
PACED	0,52	0	0	99,48

Si en general se evalúa la exactitud de los multclasificadores generados, el que mejor capacidad de clasificación ofreció para todas las clases fue el implementado con la función *kernel* RBF con $\gamma \geq 3$, con un 90% aproximadamente al igual que cuando se evaluó la especificidad y sensibilidad.

Sin embargo, si comparamos el mejor de los multclasificadores implementados con otras técnicas, referenciadas en la literatura, que realizaron clasificación de complejos QRS normales, PVC, APC y PACED, se tiene lo siguiente:

- Yun-Chi Yeh *et al.* en 2009, en su trabajo "*Cardiac arrhythmia diagnosis method using linear discriminant analysis on ECG signal*", implementaron un algoritmo de clasificación utilizando como parámetros de entrada la duración del QRS, duración del intervalo QTP y el área de RST. La evaluación fue realizada obteniendo la matriz de confusión y calculando la sensibilidad (Se) y especificidad (Ep), pero para la clasificación de complejos QRS normales, PVC, APC, bloqueo de la rama derecha y de la rama izquierda de un mismo registro de la base de datos de arritmias cardíacas del MIT-BIH [57]. En la

Tabla 24 se muestra la tabla comparativa entre los resultados reportados por estos autores y los obtenidos en este trabajo.

Se debe resaltar que para la obtención de las medidas de calidad Se y Ep, se evaluó el multclasificador entrenado en el segundo caso de prueba con *kernel* RBF con $\gamma \geq 3$, con los vectores de entradas especificados en la Tabla 19, destacándose que para el caso del registro 113, el clasificador fue entrenado con latidos QRS APC pero no, con latidos APC aberrados o tipo 4 según la codificación utilizada para las anotaciones de la base de datos, sin embargo se observa que el clasificador es eficiente para estos casos en particular.

Tabla 24. Comparación de las medidas de calidad de clasificación entre el clasificador implementado y el desarrollado por Yun, Wen y Che [57]

REGISTRO	TÉCNICA EVALUADA					
	Yun, Wen, Che			DESSARROLLADA EN ESTE TRABAJO		
	Número de Latidos	Se	Ep	Número de Latidos	Se	Ep
103	2083 Normales 2 APC	99,27	100	2078 Normales 2 APC	100	100
113	1789 Normales 6 APC Aberrados*	98,54	100	1780 Normales 6 APC ABERRADOS*	99	100
123	1515 Normales 2 PVC	97,03	100	1780 Normales 3 PVC	100	100

(*) Los latidos APC Aberrados son una arritmia cardíaca diferente a la APC y está codificada en la base de datos del MIT-BIH como tipo 4.

- Song, M., Lee, J., Park H. y Lee, K. J en 2005, en su trabajo "*Classification of Heartbeats based on Linear Discriminant Analysis and Artificial Neural Network*", utilizaron características de la primera derivada de un registro electrocardiográfico y el intervalo RR y aplicaron análisis lineal discriminante con redes neuronales y lógica difusa obteniendo una tasa de clasificación del 87% para latidos normales, 92.33% para PVC, 97.5% para APC y 90% para latidos tipo PACED [62].

En base a los resultados obtenidos en la evaluación de la exactitud, sensibilidad y especificidad de los clasificadores entrenados en este trabajo y comparándolos con los resultados obtenidos por algunos autores que clasifican

complejos QRS Normales, APC, PVC y PACED, el mejor clasificador entrenado fue el de función *kernel* RBF con $\gamma \geq 3$, cuyas medidas de evaluación se muestran en la Figura 28.




Figura 28. Medidas de evaluación del clasificador implementado en este trabajo con *kernel*RBF $\gamma \geq 3$.

CAPÍTULO V

CONCLUSIONES Y RECOMENDACIONES

"Es de importancia para quien desee alcanzar una certeza en su investigación, el saber dudar a tiempo."
Aristóteles.

En este trabajo se implementó un multclasificador basado en máquinas de soporte vectorial para complejos QRS que conforman un electrocardiograma, de su desarrollo se puede concluir:

- Las características que permiten la evaluación y clasificación de anomalías en la señales electrocardiográficas que caracterizan un tipo específico de arritmia, son diversas, sin embargo, existen generalidades que permiten la identificación de complejos QRS, siempre que sea eliminado el ruido que se incorpora a la señal en el proceso de adquisición.
- El mejor clasificador entrenado y evaluado en este trabajo fue un multclasificador de función *kernel* radial de base gaussiana, con $\gamma=3$, $\epsilon=0,001$, $C=1$, y caché de 35 Mb, con el que se obtuvo una exactitud de clasificación desde el 90 %, para todas las clases, lo que es indicativo que las MSV son adecuadas para este tipo de investigación.
- Un aspecto importante en el diseño de clasificadores basados en máquinas de soporte vectorial es la selección de la herramientas de software y hardware utilizado para la optimización, de esto depende el tiempo de entrenamiento y la evaluación de los clasificadores.
- Los multclasificadores diseñados a partir de máquinas de soporte vectorial, son una generalización de clasificadores binarios.
- Es importante la evaluación de los parámetros ϵ y C de entrada para la optimización, valores muy pequeños se reflejan en un mayor número de iteraciones y en las tasas de acierto.

- Los clasificadores de más de dos clases diseñados con máquinas de soporte vectorial, tienen la capacidad de clasificar con eficiencia variaciones de las clases con las que previamente fueron entrenados, para este trabajo fueron capaces de clasificar APC Aberrados, dentro de la categoría APC.

Como una manera de apoyar el diagnóstico basado en ECG, por computadora, se recomienda lo siguiente:

- Realizar evaluaciones con base de datos distintas a la de arritmias cardíacas del Instituto Tecnológico de Massachuset, con el objetivo de evaluar señales con diferente resolución y frecuencias de muestreo, a pesar que la muestra estudiada no arrojó diferencia significativa entre género pudiera evaluarse con una muestra de mayor tamaño.
- Realizar pruebas con otros tipos de algoritmos de parametrización de las señales ECG.
- Desarrollar esquemas que mezclen las MSV con otras técnicas propias de la inteligencia artificial o de estadística clásica para realizar este tipo de diagnóstico.
- Incorporar la Teoría de aprendizaje estadístico y Máquinas de soporte vectorial a las asignaturas del postgrado en estadística.

REFERENCIAS BIBLIOGRÁFICAS

- [1] Organización Mundial de la Salud, Centro de Prensa. Enfermedades cardiovasculares. Nota informativa Número 317. 2007.
- [2] Organización Panamericana de la Salud. Las enfermedades cardiovasculares en las Américas: Hoja informativa, (2009), p.p 1 Disponible en: [http://new.paho.org //index2.php?option=com_docman&task=docview_gid=3823 &Itemid=](http://new.paho.org//index2.php?option=com_docman&task=docview_gid=3823&Itemid=)
- [3] Acharya, R., Bhat, P. S., Iyengar, S. S., Roo, A., Dua, S. (2002) Classification of heart rate data using artificial neural network and fuzzy, equivalence relation. The Journal of the Pattern Recognition Society.
- [4] Mehta, S., Lingayat, N., (2008), Combined entropy based method for detection of QRS complexes in 12-lead electrocardiogram using SVM. Computers in Biology and Medicine, Vol. 38, p.p 138-145.
- [5] Chaoyang Zhang, Peng Li, Arun Rajendran, Youping Deng, Dequan Chen (2006) Parallelization of multicategory support vector machines (PMC-SVM) for classifying microarray data. BMC Bioinformatics. 7 (Suppl 4).
- [6] Vapnik, V. (1995). The nature of statistical Learning Theory. Springer-Verlag
- [7] Seijas, C. Caralli, A., Villazana, S. (2008). Predicción de Hipertensión Arterial Usando Máquinas de Vectores de Soporte. Desarrollo y avances de métodos numéricos para ingeniería y ciencias aplicadas. Sociedad Venezolana de métodos numéricos en ingeniería. BI-8.
- [8] Ferguson, S., Dunlop, G. (2002) Reg. Grasp Recognition From Myoelectric Signals. Proc. 2002 Australasian Conference on Robotics and Automation, Auckland, 27 – 29.
- [9] Englehart, K., (1998) Signal Representation for Classification of the Transient Myoelectric Signal. Ph.D. Thesis, University of New Brunswick, Fredericton, New Brunswick.

- [10] Benitez, D., Gaydecki, P., Zaidi, A., Fitzpatrick, A., (2001), The use of the Hilbert transform in ECG signal analysis, *Comput. Biol. Med.*, Vol. 31, pp. 399 – 406.
- [11] Koski, A., (1996), Modelling ECG signals with Hidden Markov Models, *Artif. Intell. Med.* ,Vol. 8, pp. 453 – 471.
- [12] Li C., Zheng C, Tai C., (1995), Detection of ECG characteristic points using wavelet transform, *IEEE Trans. Biomed. Eng.* Vol. 42 , pp. 21–28.
- [13] Yeh Y., Wang W., Chiou C., (2009), Cardiac Arrhythmia Diagnosis Method using Linear Discriminant Analysis on ECG Signals. *Measurement*,42, Vol. 01.
- [14] Gholam, H., Luob ,D., Reynolds, K., (2006), The comparison of different feed forward neural network architectures for ECG signal diagnosis. *Medical Engineering & Physics*, Vol. 28, pp. 372 – 378.
- [15] Mukherjee, S., Osuna, E., Girosi, F., (1997), Nolinear predic
- [16] Elif Derya Übeyli (2007) ECG beats classification using multiclass support vector machines with error correcting output codes. *Digital Signal Processing* 17. 675 – 684
- [17] Acr, N., (2006) A support vector machine classifier algorithm based on a perturbation method and its application to ECG beat recognition systems. *Expert Systems with Applications* 31. 150 – 158.
- [18] Sejías, C. Caralli, A., Villazana, S. (2010). Agrupamiento basado en máquinas de vectores de soporte de señales ECG normales y patológicas. *Modelos computacionales en ingeniería. Sociedad Venezolana de métodos numéricos en ingeniería.* PS-175.
- [19] The World Health Organization, "The Atlas of Heart Disease and Stroke", Disponible:[http:// www.who.int/cardiovascular_diseases](http://www.who.int/cardiovascular_diseases), [Consultada: Agosto 2006]
- [20] Almeida, R., González, R., Rodríguez, A., Rodríguez, G., (2007), Sistema para el monitoreo continuo de ECG: Cardioestudio, *IFMBE Proceedings* 18, pp. 175 – 177.

- [21] Saxena S.C., Kumar, V., Hamde, S.T., (2002), Feature extraction from ECG signals using wavelet transforms for disease diagnostics, *Int. J. Syst. Sci.* 33 (13) 1073 –1085.
- [22] Foo, S.Y., Stuart, G., Harvey, B., Meyer-Baese, A. (2002), Neural network-based EKG pattern recognition, *Eng. Appl. Artific. Intell.* 15 253 – 260.
- [23] Maglaveras, N., Stamkopoulos, Diamantaras , T., K., Pappas, C., Strintzis, M., (1998), ECG pattern recognition and classification using non-linear transformations and neural networks: A review, *Int. J. Med. Inform.* 52 191 –208.
- [24] Ministerio del Poder popular para la salud. Anuario de Mortalidad, (2006), Disponible en: http://www.mpps.gob.ve/ms/direcciones_msds/Epidemiologia/Es-tadistica/Index.htm [Consultado, Diciembre 2008]
- [25] H. Vélez, W. Rojas, J. Borrero, J. Restrepo, (1996), Manual de Electrocardiografía. 4ta. Edición. Corporación para Investigaciones Biológicas. Medellín, Colombia.
- [26] Texas heart institute, at. Lukes Epicopal Hospital, Anatomía del corazón, Disponible en: <http://www.texasheartinstitute.org/HIC/anatomEsp.cfm> [Consultado, Diciembre 2008]
- [27] The Biology Corner, Interpreting ECG, <http://www.biologycorner.com/anatomy/circulatory/ecg.html> [Consultado, Diciembre 2008]
- [28] Gonzáles (s.f.). Sistema Tutor en Electrocardiografía Unidad 1. [Multimedia en DC]. Grupo Boehringer Ingelheim. Disponible en: Universidad Nacional Experimental del Táchira.
- [29] L. López (1995). Electrocardiografía. En D. Almeida y S. Brandi (Comp.), Manual de Cardiología Clínica. Tomo 1. 2da Edición. Universidad Central de Venezuela. Caracas, Venezuela.
- [30] University of Virginia, Health System. Los trastornos cardiovasculares. Disponible en http://www.healthsystem.virginia.edu/uvahealth/peds_cardiac_sp/rrhythm.cfm, [consultado en Abril 2009]
- [31] Karnes, Nancy J.(1985), Contracciones ventriculares prematuras: cuando suena la alarma. *Nursing.* 3(3): p.p 9 – 13.

- [32]Barro, S., Fernandez, M., Delgado, J., Vila, C., Regueiro, V., Sánchez, E., (1998), Classifying multichannel ECG patterns with an adaptive neural network. IEEE Eng. in Med. and Bio.,p.p. 45–55.
- [33]About AAMI, (2009), Association for the Advancement of Medical Instrumentation. Disponible en: <http://www.aami.org/standards/smo.html> [Consultada Abril 2009].
- [34]Massachusetts Institute of Technology. PhysioNet: A Resource for Research and Education. Disponible en: <http://www.physionet.org/resource.shtml/> [Consultada Diciembre 2008]
- [35]Cherkassky, V., Mulier, F., (2007). Learning from Data: Concepts, Theory, and Methods. IEEE Computer Society Press.
- [36]Vapnik, V., (1998), Statistical Learning Theory, Jhon Wiley and Son
- [37]Cortes, C., Vapnik, V. (1995). Support vector networks. Machine Learning, 20:1-25.
- [38] Rengifo, P., Jimenez, L. (1995), Máquinas de Soporte Vectorial Fundación universitaria Konrad Lorenz
- [39]Boser, B., Guyon, I., Vapnik, V., (1992), A Training Algorithm for Optimal Margin Classifiers.
- [40]German, S., Bienenstock, E.(1992). Neural networks and the bias / variance dilemma. Neural Computacion, 4:1– 58,
- [41] Guyon, I., Vapnik, V., Boser, B., Bottou, L., Solla, S., (1992), Structural risk minimization for character recognition. Advances in Neural Information Processing Systems, 4:471–479.
- [42]Angulo, C., González, L.(2003). 1-v-1 Tri-class SV machine. ESANN'2003.
- [43]González, A. (2001). Modelos de Clasificación basados en Máquinas de Vectores Soporte, Universidad de Sevilla-Departamento de Economa Aplicada.
- [44]Vapnik, V., (1995), The Nature of Statistical Learning Theory. Disponible: <http://www.cscs.umich.edu/~crshalizi/reviews/vapnik-nature/> [Consultada Enero 2009].

- [45]Boser, B., (1992). A training algorithm for optimal margin classifiers. Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory.
- [46]Hernández, J., Quintana M., Ferri, C., (2004) Introducción a la minería de datos. Editorial Pearson
- [47]Pina, N., González, R., Rodríguez, A., Almeida, R., Rodríguez, G., Montes de Oca, G. (2009) Herramienta para la evaluación de algoritmos de interpretación del ECG utilizando la Base de Datos CSE MULTILEAD LIBRARY. Revista de bioingeniería y física médica cubana. Vol. 9 No. 1.
- [48]Mitchell, T., (1997), Machine Learning. MvGraw Hill.
- [49]Kressel, U., (1999), Pairwise classification and support vector machine, Advances in kernel methods support vector learning. MIT Press.
- [50]Solera, R., Pérez, F., Díaz, F., Estimación de probabilidades a posteriori en SVMs para el reconocimiento del habla continua.
- [51]Witten, F., (2000), Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations.
- [52]Archivos de señales fisiológica para la investigación biomédica PhysioBank, ECGcodes, códigos de anotación ECG, disponible en: <http://www.physionet.org/physio/ols/wfdb/lib/ecgcodes.h> (Consultada Marzo 2009).
- [53]PhysioToolkit. Open source software for biomedical science and engineering. Disponible en: <http://www.physionet.org/physiotools/> (Consultada Abril 2009)
- [54]Kligfield, P., Gettes, L., Bailey, R., (2007). Recommendations for the Standardization and Interpretation of the Electrocardiogram: Part I: The Electrocardiogram and Its Technology: A Scientific Statement From the American Heart Association Electrocardiography and Arrhythmias Committee, Council on Clinical Cardiology; the American College of Cardiology Foundation; and the Heart Rhythm Society Endorsed by the International Society for Computerized Electrocardiology, Disponible en: <http://circ.aha.org/journals.org/cgi/reprint/CIRCULATIONAHA.106>. [Consultada Abril 2009]
- [55]Thakor, N., Webster, J., Tompkins, W., (1984), Design, implementation, and evaluation of a microcomputer-based portable arrhythmia monitor. Med. Biol. Eng. Comput, Vol. 22, p.p 151 159.

- [56] Pan, J., Tompkins, W., (1985) A real-time QRS detection algorithm. IEEE Trans. Biomed. Eng., BME-32(3),230 – 236.
- [57]Yun-Chi Yeh, Wen-June Wang, Che Wun Chiou (2009) Cardiac arrhythmia diagnosis method using linear discriminant analysis on ECG signals. Measurement. 42, 778 - 789.
- [58]Mehta, S., Shete, D., Lingayat, N., Chouhan, V., (2010) K-means algorithm for the detection and delineation of QRS-complexes in Electrocardiogram. IRBM 31, 48– 54.
- [59]Software. kernel-machine.org. Disponible en: <http://www.kernel-machines.org/software> [Consultada Abril 2009].
- [60] Chang, C., Chih-Jen L. (2010), LIBSVM, Disponible en: <http://www.csie.ntu.edu.tw/~cjlin/libsvm/> (Consultada Enero 2010)
- [61] Junshi M., Zhao Y. (2002), Support vector machine, Toolbox for MATLAB. Disponible en: <http://www.kernel-machines.org/software> [Consultada Abril 2009].
- [62]Song M., Lee J., Park H. , Lee K., (2005) Classification of Heartbeats based on Linear Discriminant Analysis and Artificial Neural Network, Engineering in Medicine and Biology IEEE, 1151 1153.

ANEXOS

www.bdigital.ula.ve

ANEXO A

www.bdigital.ula.ve
carga.m

```

function cosas = carga(registro,ventana,Tventana,derivacion)
% ALGORITMO QUE OBTIENE EL INTERVALO DE SEÑAL DE INTERES DE CUALQUIERA
% DE LAS 2 DERIVACIONES DE LOS REGISTROS DE FORMATO BINARIO 212.

% =====
% 1. CARGA EL ARCHIVO DE DATOS
% =====
%

% A 360 muestras por segundo, a sesenta segundos por minuto, para un
% total de 650.000 mueatras

etiqueta= 1;
umbralS= 20;
umbralP= 50;
umbralST =110;
umbralT=80;
umbralC=50;

%----- Especificacion de los datos -----

registro = num2str(registro);          % Convierte un numero a string
RUTA= 'C:\Documents and Settings\USUARIO\Mis documentos\ECG';
% ruta donde los datos estan almacenados

CABECERA= strcat(registro, '.hea');    % Cabecera del archivo en formato .txt
A_ATRIBUTO= strcat(registro, '.atr');  % atributos del archivo en formato binario
A_DATOS= strcat(registro, '.dat');    % archivo de datos
M_LEIDAS=650000;                      % numero de muestras a leer (30 min)*(60
s.)*(360 muestra/s)

% todo el archivo se necesitan 648000

fprintf(1, '\n$> Trabajando sobre la ventana %d ...\n', ventana);
ECG.tini= (ventana*Tventana)-(Tventana -1); %Calcula la muestra de inicio
ECG.tfin= ECG.tini+ (Tventana-1);          %Calcula la muestra final
fprintf(1, '\n$> Numero de muestra inicial: %d ...\n', ECG.tini);
fprintf(1, '\n$> Numero de muestra final: %d ...\n', ECG.tfin);

% ----- Leer la cabecera de los datos -----

fprintf(1, '\n$> Trabajando sobre %s ...\n', CABECERA);
signalh= fullfile(RUTA, CABECERA); % Crea la ruta completa del archivo el path + nombre
% del archivo cabecera
fidl=fopen(signalh, 'r');             % abre el archivo cabeceras para leerlo
z= fgetl(fidl);
A= sscanf(z, '%*s %d %d %d', [1,3]); % leer la cabecera
nosig= A(1);                          % número de señales
sfreq=A(2);                            % frecuencia de muestreo de los datos
clear A;
for k=1:nosig
    z= fgetl(fidl);
    A= sscanf(z, '%*s %d %d %d %d %d', [1,5]);
    dformat(k)= A(1);                  % solamente se puede leer el formato binario 212
    gain(k)= A(2);                     % número de enteros por mV

```



```

        bitres(k)= A(3);           % resolución en bits
        zerovalue(k)= A(4);       % valor entero del punto cero del ECG
        firstvalue(k)= A(5);     % primer valor entero de la señal
    end;
    fclose(fid1);
    clear A;

% ----- Cargando datos binarios -----

    if dformat~= [212,212], error('Este scrip no aplica a formatos binarios distintos al
212.');
```

www.bdigital.ula.ve

```

    end;
    signald= fullfile(RUTA, A_DATOS); % Crea la ruta completa del archivo el path +
nombre
                                % del archivo de datos
    fid2=fopen(signald,'r');      % Lee el archivo de datos
    A= fread(fid2, [3, M_LEIDAS], 'uint8');
```

www.bdigital.ula.ve

```

% carga el archivo de datos con resolucion de 8 bits

    fclose(fid2);
    M2H= bitshift(A(:,2), -4);
    M1H= bitand(A(:,2), 15);
    PRL=bitshift(bitand(A(:,2),8),9);
    PRR=bitshift(bitand(A(:,2),128),5);
    M( : , 1)= bitshift(M1H,8)+ A(:,1)-PRL;
    M( : , 2)= bitshift(M2H,8)+ A(:,3)-PRR;
    if M(1,:) ~= firstvalue, error('Inconsistencia en el primer valor');
```

www.bdigital.ula.ve

```

    end;
    switch nosig
    case 2
        M( : , 1)= (M( : , 1)- zerovalue(1))/gain(1);
        M( : , 2)= (M( : , 2)- zerovalue(2))/gain(2);
        TIME=(0:(M_LEIDAS-1))/sfreq;
    case 1
        M( : , 1)= (M( : , 1)- zerovalue(1));
        M( : , 2)= (M( : , 2)- zerovalue(1));
        M=M';
        M(1)=[];
        sM=size(M);
        sM=sM(2)+1;
        M(sM)=0;
        M=M';
        M=M/gain(1);
        TIME=(0:2*(M_LEIDAS)-1)/sfreq;
    otherwise %

        disp('!!');
    end;
    clear A M1H M2H PRR PRL;
    fprintf(1,'\n$n$> Cargado de Datos terminado \n');
```

www.bdigital.ula.ve

```

% ----- CARGAR LOS ATRIBUTOS DE LOS DATOS -----

    atrd= fullfile(RUTA, A_ATRIBUTO); % Archivo de atributos con los datos
    fid3=fopen(atrd,'r');
    A= fread(fid3, [2, inf], 'uint8');
```

```

fclose(fid3);
ATRTIME=[];
ANNOT=[];
sa=size(A);
saa=sa(1);
i=1;
while i<=saa
    annoth=bitshift(A(i,2),-2);
    if annoth==59
        ANNOT=[ANNOT;bitshift(A(i+3,2),-2)];
        ATRTIME=[ATRTIME;A(i+2,1)+bitshift(A(i+2,2),8)+...
            bitshift(A(i+1,1),16)+bitshift(A(i+1,2),24)];
        i=i+3;
    elseif annoth==60
        %
    elseif annoth==61
        % !
    elseif annoth==62
        %
    elseif annoth==63
        hilfe=bitshift(bitand(A(i,2),3),8)+A(i,1);
        hilfe=hilfe+mod(hilfe,2);
        i=i+hilfe/2;
    else
        ATRTIME=[ATRTIME;bitshift(bitand(A(i,2),3),8)+A(i,1)];
        ANNOT=[ANNOT;bitshift(A(i,2),-2)];
    end;
    i=i+1;
end;
ANNOT(length(ANNOT))=[]; % proxima línea = EOF (=0)
ATRTIME(length(ATRTIME))=[]; % próxima línea = EOF
clear A;
ATRTIME= (cumsum(ATRTIME))/sfreq;
ind= find(ATRTIME <= TIME(end));
ATRTIMED= ATRTIME(ind);
ANNOT=round(ANNOT);
ANNOTD= ANNOT(ind);

```

```

% =====
% 2. SE ALMACENAN EN LA ESTRUCTURA ECG.*, LAS ANOTACIONES, LOS DATOS Y LA
% LINEA DE TIEMPO.
% =====
    ECG.anota=ANNOTD;
    ECG.valores = M(:,derivacion);
    ECG.valoresp = ECG.valores(ECG.tini:ECG.tfin);
    ECG.TIME=TIME(ECG.tini:ECG.tfin);

    save ECG

% =====

```

ANEXO B

www.bdigital.ula.ve
filtro.m

```
function cosas = filtro()
% ALGORITMO QUE filtra una señal ECG

% =====
% 1. CARGA EL ARCHIVO DE DATOS
% =====

load ECG
a = lowpassfilter1(ECG.valoresp);
b = highpassfilter(a);

save b
% =====
```

www.bdigital.ula.ve

ANEXO C

Vintegradora.m

www.bdigital.ula.ve

```

function [ y ] = Vintegradora(valores)
% Variables de entrada
% valores - Valores de la Señal de entrada
% Variables de salida
% y - Valores de salida filtrados

N = 30; % Contiene el numero de muestras a estudiar en la ventana
      % 83,3 ms.
y = zeros(size(valores));

for i = 1:length(values)
    if ( i <= N )
        k = i-1;
    else
        k = N;
    end
    for j = 0:k
        y(i) = y(i) + values(i-j);
    end
    y(i) = y(i) / N;
end

```

www.bdigital.ula.ve

ANEXO D

clasifica.m

www.bdigital.ula.ve

```

function cosas=clasifica(kernel, Degree, Gamma)

load entrena

size(Labels)
size(Samples)

%=====
% CONSTRUYE UN CLASIFICADOR SVM
%=====

if (nargin < 3)
    Gamma = 2;
else
    if (nargin < 2)
        Degree = 2;
    end
end

end

if ((kernel <= 0) | (kernel > 4))
    fprintf(1, '\\n$> Kernel incorrecto \n');
else
    if (kernel ==1)
        [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = LinearSVC(Samples, Labels);
    end
    if (kernel ==2)
        [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = PolySVC(Samples, Labels, Degree);
    end
    if (kernel ==3)
        [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = RbfSVC(Samples, Labels, Gamma);
    end
end

end

% Muestra las variables del clasificador

AlphaY
SVs
Bias
Parameters
nSV
nLabel

% Fin de la construccion del Clasificador
% El resultado del clasificador es:
% "AlphaY", "SVs", "Bias", "Parameters", and "Ns".
%

% Se guarda el clasificador construido
save SVMClasificador AlphaY SVs Bias Parameters nSV nLabel;

%=====

```



```

function [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = LinearSVC(Samples, Labels,C)
% USOS:
%   [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = LinearSVC(Samples, Labels)
%   [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = LinearSVC(Samples, Labels,C)
%
% DESCRIPCION:
%   Construye un clasificador SVM, de kernel lineal
%
% ENTRADAS:
%   Samples: Todos los vectores de entrenamiento
%   Lables:  Corresponde a las etiquetas por clase, de cada vector de
%   entrada
%   C: Costo (por defecto 1)
%
% SALIDAS:
%   AlphaY    - Alpha * Y, donde alfa son los multiplicadores de lagrange
%               distintos de cero
%   SVs       - Vectores de soporte.(Vectores de entradas correspondientes
%               a los alfa distintos de cero), M x sum(nSV),
%   Bias      - Sesgo de cada uno de los clasificadores binarios,
%               1 x L*(L-1)/2;
%   Parameters - Parametros de salida usados durante el entrenamiento;
%   nSV       - Numero de vectores de soporte de cada clase, 1xL;
%   nLabel    - Etiquetas de cada clase, 1xL.
%
% Propuesto por: Junshui Ma, and Yi Zhao (02/15/2002)
%
if (nargin < 2) & (nargin > 3)
    disp(' Numero incorrecto de variables de entrada.\n');
    help LinearSVC;
    return;
else
    if (nargin <=2)
        Parameters = [0];
        [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = SVMTrain(Samples, Labels,
Parameters);
    else
        Parameters = [0 1 1 1 C];
        [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = SVMTrain(Samples, Labels,
Parameters);
    end
end
end

```

```

function [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = PolySVC(Samples, Labels, Degree,
C, Gamma, Coeff)
% USOS:
% [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = PolySVC(Samples, Labels)
% [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = PolySVC(Samples, Labels, Degree)
% [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = PolySVC(Samples, Labels, Degree, C)
% [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = PolySVC(Samples, Labels, Degree, C,
Gamma, Coeff)
%
% DESCRIPCION:
% Construccion de un SVM clasificador con kernel polinomico.
% ENTRADAS:
% Samples: Todos los vectores de entrenamiento
% Lables: Corresponde a las etiquetas por clase, de cada vector de
% entrada
% Degree, Gamma, y Coeff: parametros del kernel polinomial, Expresado:
% (Gamma*X(:,i),X(:,j))+Coefficient)^Degree
% Degree --- (Por defecto: 3)
% Gamma --- (Por defecto: 1)
% Coeff --- (Por defecto: 1)
% C: Costo (por defecto 1)
% SALIDAS:
% AlphaY - Alpha * Y, donde alfa son los multiplicadores de lagrange
% distintos de cero
% SVs - Vectores de soporte. (Vectores de entradas correspondientes
% a los alfa distintos de cero), M x sum(nSV),
% Bias - Sesgo de cada uno de los clasificadores binarios,
% 1 x L*(L-1)/2;
% Parameters - Parametros de salida usados durante el entrenamiento;
% nSV - Numero de vectores de soporte de cada clase, 1xL;
% nLabel - Etiquetas de cada clase, 1xL.
%
% Propuesto por: Junshui Ma, and Yi Zhao (02/15/2002)
%
if (nargin < 2) & (nargin > 6)
disp(' Numero incorrecto de variables de entrada.\n');
help PolySVC;
return;
else
if (nargin == 2)
Parameters = [1];
[AlphaY, SVs, Bias, Parameters, nSV, nLabel] = SVMTrain(Samples, Labels,
Parameters);
elseif (nargin == 3)
Parameters = [1 Degree];
[AlphaY, SVs, Bias, Parameters, nSV, nLabel] = SVMTrain(Samples, Labels,
Parameters);
elseif (nargin == 4)
Parameters = [1 Degree, 1, 1, C];
[AlphaY, SVs, Bias, Parameters, nSV, nLabel] = SVMTrain(Samples, Labels,
Parameters);
elseif (nargin == 6)
Parameters = [1 Degree, Gamma, Coeff, C];
[AlphaY, SVs, Bias, Parameters, nSV, nLabel] = SVMTrain(Samples, Labels,
Parameters);
end
end
end

```

```

function [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = RbfSVC(Samples, Labels, Gamma,
C)
% USOS:
%   [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = RbfSVC(Samples, Labels)
%   [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = RbfSVC(Samples, Labels, Gamma)
%   [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = RbfSVC(Samples, Labels, Gamma, C)
%
% DESCRIPCION:
%   Contruccion de un clasificador SVM con kernel de base radial gaussiana
%
% ENTRADAS:
%   Samples: Todos los vectores de entrenamiento
%   Lables: Corresponde a las etiquetas por clase, de cada vector de
%   entrada
%   Gamma: Parametro del kernel de base radial, expresado como:
%           (exp(-Gamma*|X(:,i)-X(:,j)|^2)). (por defecto 1)
%   C: Costo (por defecto 1)
%
% SALIDAS:
%   AlphaY - Alpha * Y, donde alfa son los multiplicadores de lagrange
%           distintos de cero
%   SVs - Vectores de soporte. (Vectores de entradas correspondientes
%   a los alfa distintos de cero), M x sum(nSV),
%   Bias - Sesgo de cada uno de los clasificadores binarios,
%   1 x L*(L-1)/2;
%   Parameters - Parametros de salida usados durante el entrenamiento;
%   nSV - Numero de vectores de soporte de cada clase, 1xL;
%   nLabel - Etiquetas de cada clase, 1xL.
% Propuesto por: Junshui Ma, and Yi Zhao (02/15/2002)
%
if (nargin < 2) & (nargin > 4)
    disp(' Numero incorrecto de variables de entrada.\n');
    help RbfSVC;
    return;
else
    if (nargin == 2)
        Parameters = [2];
        [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = SVMTrain(Samples, Labels,
Parameters);
    elseif (nargin == 3)
        Parameters = [2 1 Gamma];
        [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = SVMTrain(Samples, Labels,
Parameters);
    elseif (nargin == 4)
        Parameters = [2 1 Gamma 1 C];
        [AlphaY, SVs, Bias, Parameters, nSV, nLabel] = SVMTrain(Samples, Labels,
Parameters);
    end
end
end

```

ANEXO E

[www.bdigital.ula.ve](http://www.bdigital.ula.ve/prueba.m)

```

function cosas= prueba()

% =====
% FUNCION QUE OBTIENE LA MATRIZ DE CONFUSION DE UN CLASIFICADOR SVM PREVIAMENTE
% CONSTRUIDO
% =====

clear all           % Limpia todas las variables
load SVMClasificador % Carga el clasificador a evaluar

pause % Presione una tecla para continuar

who

pause % Presione una tecla para continuar

% Carga los datos de prueba
load prueba

pause % Presione una tecla para continuar

% Test the constructed SVM classifier using the test data
% Comienza la prueba ...
[ClassRate, DecisionValue, Ns, ConfMatrix, PreLabels]= SVMTest(Samples, Labels, AlphaY,
SVs, Bias,Parameters, nSV, nLabel);
% finaliza la prueba

pause % Presione una tecla para continuar

% Matriz de confusion resultante

ConfMatrix

pause% Presione una tecla para continuar

% =====

```