

Procesamiento de Señales Electrocardiográficas en Equipos Portátiles mediante Estrategias Online de Inteligencia Computacional

Marcos Alvarez^{†1}, Laura Díaz Dávila^{†2}, Guillermo Riva^{†3}

[†]FCEFYN, Universidad Nacional de Córdoba, Córdoba, Argentina

¹marcos.alvarez.91@gmail.com

²laura.diaz@unc.edu.ar

³guillermo.riva@unc.edu.ar

[‡]GInTEA, Universidad Tecnológica Nacional, Facultad Regional Córdoba, Argentina

³griva@frc.utn.edu.ar

Resumen—Portable cardiac monitoring devices acquire and store all electrocardiography data of a patient for 24 hours, which are then analyzed by medical professionals. However, certain cardiac abnormalities occur sporadically and are not recorded. In addition, it is of great importance to preprocess the data acquired in real time to filter data and generate alarms. This imposes the use of simple computational strategies for limited resources portable devices. This paper presents the development of an algorithm that allows portable electrocardiography devices to make data storage/transmission more efficient than traditional monitoring equipment. The algorithm performs filtering and segmentation of the signal based on simple transformations and detection of peaks. Then, the beats are decomposed into 5 characteristics by Independent Component Analysis, and classified by one-class Support Vector Machine. The classification used is binary (normal or abnormal beats), not allowing to specify pathologies, but reducing the data. The algorithm was tested with 20500 normal beats and 6500 abnormal beats, reducing data storage/transmission by 64 %, with 99 % accuracy. The robustness was verified on the detection and classification of the beats, and a proof of concept was performed to validate the proposal.

Resumen— Los dispositivos portátiles para monitoreo cardiológico adquieren y almacenan todos los datos de electrocardiografía de un paciente por 24 horas, los cuáles son analizados posteriormente por el profesional médico. Sin embargo, ciertas anomalías cardíacas se producen esporádicamente y no son registradas. Además, es de gran importancia preprocesar los datos adquiridos en tiempo real para filtrar datos y generar alarmas. Sin embargo, esto impone el uso de estrategias computacionales simples para dispositivos portátiles con recursos limitados. Este trabajo presenta el desarrollo de un algoritmo que permite a dispositivos portátiles de electrocardiografía hacer más eficiente el almacenamiento/transmisión de datos respecto a los equipos de monitoreo tradicionales. El algoritmo realiza filtrado y segmentación de la señal basado en transformaciones sencillas y la detección de picos. Luego, los latidos son descompuestos en 5 características mediante Análisis de Componentes Independientes, y clasificados mediante Máquina de Vectores de Soportes de una clase. La clasificación utilizada es binaria (latidos normales o anormales), no permitiendo especificar patologías, pero reduciendo los datos. El algoritmo fue probado con 20500 latidos normales y 6500 anormales, reduciendo el almacenamiento/transmisión de datos un 64 %, con 99 % de precisión. Se verificó robustez al ruido sobre la detección y clasificación de los latidos, y se realizó una prueba de concepto para validar la propuesta.

I. INTRODUCCIÓN

Los dispositivos portátiles para monitoreo cardiológico de pacientes (hollers) permiten adquirir y almacenar datos de electrocardiografía, en general, por un lapso máximo de 24 horas, equivalente al registro de cerca de 100000 latidos. Estos dispositivos son alimentados con baterías y poseen memorias regrabables. Los datos adquiridos y almacenados son analizados posteriormente de manera offline por el profesional médico. Sin embargo, en muchos casos, ciertos eventos cardíacos anormales se producen en un periodo de tiempo mayor, y no son registrados por estos sistemas. Por otro lado, es de gran utilidad un sistema que realice un pre-procesamiento de los datos adquiridos en tiempo real (online), por ejemplo, para almacenar/transmitir solo patrones cardíacos anómalos detectados, para generar algún tipo de alarma, etc. Esto permite reducir en gran medida el uso de memoria y de transmisión de datos, con el consecuente ahorro de energía del equipo. Sin embargo, la implementación de estrategias de procesamiento en dispositivos portátiles, con procesadores de 8, 16 o 32 bits de bajo consumo, impone el requerimiento de estrategias computacionales eficientes que no demanden un procesamiento significativo. Ello se debe a la baja capacidad de procesamiento de los dispositivos portátiles, dado que una mayor capacidad reduciría su capacidad de autonomía energética [1], [2].

Este trabajo presenta el desarrollo de un mecanismo que permite a dispositivos portátiles de electrocardiografía (ECG) pasar de un esquema de adquisición, almacenamiento y/o transmisión de datos, a un esquema más eficiente basado en la determinación de si es necesario el almacenamiento y/o transmisión de los patrones adquiridos. El algoritmo diseñado, realiza el filtrado y la segmentación de la señal de ECG basado en transformaciones sencillas y la detección de picos. Luego, los latidos son descompuestos mediante el Análisis de Componentes Independientes, resultando en un conjunto mínimo de características. Finalmente, los latidos son clasificados mediante una estrategia de inteligencia computacional denominada Máquina de Vectores de Soportes de una clase.

El electrocardiograma es un estudio de diagnóstico médico y una de las fuentes de información de mayor valor

en el estudio del funcionamiento del corazón. Su no invasividad, facilidad de obtención y escaso costo, sumado a la gran variedad de patologías cardíacas que se pueden detectar mediante su análisis, lo han convertido en un estudio de rutina en las consultas cardiológicas. Muchas de las patologías cardíacas pueden ser detectadas mediante un ECG de corta duración, que no supera los dos o tres minutos. Existe, no obstante, un importante número de enfermedades de aparición esporádica (o causada por un evento no reproducible en el momento del estudio) que requiere la realización de monitoreo móvil, de los que se obtienen registros electrocardiográficos de varias horas de duración. Los dispositivos utilizados para este monitoreo se limitan únicamente a la adquisición y almacenamiento de datos electrocardiográficos, sin analizar si los mismos son relevantes o no. Dado que los equipos de monitoreo móvil tienen memorias limitadas para almacenar datos, se tiene un almacenamiento ineficiente. Si bien numerosas técnicas y sistemas de diagnóstico asistido han sido desarrolladas intentando dar solución al problema de analizar estudios de larga duración luego de realizado el mismo (procesamiento off-line), existen muy pocas propuestas para dotar a los dispositivos de monitoreo móvil con la capacidad de análisis de los datos adquiridos (procesamiento on-line). La incorporación de algún esquema simple de procesamiento en el equipo de adquisición, como puede ser filtrar datos no relevantes, detectar patrones anormales, etc., posibilitará tanto reducir la cantidad de datos a almacenar en la limitada memoria del equipo portátil, como reducir la comunicación inalámbrica de los datos en sistemas de adquisición en tiempo real, lo cuál influye en el consumo de energía del equipo. La evolución actual de la tecnología, con procesadores con mayores capacidades computacionales y menores consumos de energía, y tecnologías de baterías de mayor capacidad posibilita cada vez más la realización de esta posibilidad. Sobre este tipo de procesamiento in situ en el equipo médico de adquisición hay escasas referencias conocidas, y se sabe que es un tema de investigación actual [9], [3].

Este trabajo se estructura de la siguiente forma. El marco teórico es detallado en el Capítulo II. En el Capítulo III se presentan los algoritmos utilizados para el procesamiento de la señal de ECG. La implementación del algoritmo propuesto en este trabajo es detallado en el Capítulo IV. Finalmente, el Capítulo V resume los resultados obtenidos, y el Capítulo VI resume las conclusiones y trabajos futuros.

II. MARCO TEÓRICO

Los temas a tratar en este trabajo, relacionados al procesamiento de señales electrocardiográficas, son organizados en dos grupos: *i) principios anatómicos y fisiológicos del funcionamiento del corazón*, que permiten entender el origen de la señal a procesar, sus características principales y los distintos patrones normales y patológicos, y *ii) principios matemáticos asociados al procesamiento de la señal electrocardiográfica*, agrupados en tres etapas de procesamiento: *detección de latidos, extracción de características y clasificación*.

II-A. Principios anatómicos y fisiológicos del corazón

El corazón es el órgano principal del sistema circulatorio, cuya función es la de propulsar la sangre a través de los

vasos sanguíneos hacia las distintas regiones del organismo, permitiendo de este modo la llegada de nutrientes y oxígeno a cada célula y la eliminación de los residuos resultantes de la actividad metabólica. En un individuo sano, el corazón pesa entre 200 y 250 gramos y su volumen es apenas mayor que el puño de la persona. El corazón es fijado y mantenido en su lugar por los grandes vasos que llegan y salen de él (venas Cava Inferior y Superior, y Pulmonares Derecha e Izquierda, y arterias Aorta y Pulmonar). Desde el punto de vista anatómico, el mismo es un órgano muscular hueco dividido en dos mitades (izquierda y derecha) por un tabique músculo-membranoso. Cada una de estas mitades constituye a su vez dos cavidades: una superior, la aurícula, y una inferior, el ventrículo.

II-B. Actividad eléctrica del corazón

Desde el punto de vista físico, el corazón constituye un sistema de dos bombas conectadas en serie: el corazón derecho se encarga de bombear la sangre con bajo contenido de oxígeno, proveniente de la circulación mayor o sistémica, y enviarla hacia los pulmones; mientras que, el corazón izquierdo, toma la sangre oxigenada proveniente de la circulación menor (de los pulmones) y la retoma nuevamente a la circulación sistémica. El bombeo de la sangre por parte del corazón es producido gracias a una secuencia ordenada de fenómenos mecánicos y eléctricos que suceden desde el comienzo de un latido hasta el comienzo del siguiente, y son conocidos como ciclo cardíaco. El mismo está compuesto por un período de contracción o sístole, seguido de un período de relajación o diástole. Dado que estos períodos de contracción y relajación no se producen en simultáneo en todo el corazón, se pueden distinguir tres tiempos distintos durante el ciclo cardíaco: la sístole auricular, la sístole ventricular, y la diástole.

El ciclo cardíaco se repite unas 50 a 100 veces por minuto en un individuo sano (frecuencia cardíaca normal), lo que establece una duración de entre 0,6 y 1,2 segundos por latido.

Al registro de las variaciones de potencial sobre la piel del paciente se lo conoce como electrocardiograma (ECG). La diferencia de potencial entre dos puntos puede lograrse ya sea empleando dos electrodos activos registrando la diferencia de polaridad entre ellos (registro bipolar), o mediante un electrodo activo y uno que se conecta a potencial cero (registro unipolar). La disposición de las conexiones de cada par de electrodos se conoce como derivación, del cuál es posible distinguir doce derivaciones diferentes, que pueden ser clasificadas en tres grupos: *derivaciones estándar de las extremidades, derivaciones aumentadas de las extremidades y derivaciones precordiales*.

El registro electrocardiográfico se compone de un grupo de ondas que representan los fenómenos de *despolarización* y *repolarización* de las distintas estructuras del corazón a lo largo de un ciclo cardíaco [4], [5]. En aquellos momentos en los que no existen variaciones del potencial eléctrico (fase isoelectrica) el trazo obtenido en un ECG constituye la línea de base o línea isoelectrica. La fase isoelectrica comprendida entre el final de una onda y el principio de la siguiente se denomina segmento, mientras que un conjunto de ondas sin la existencia de fase isoelectrica entre ellas se denomina




Figura 1. Ondas, segmentos e intervalos característicos de un ECG.

complejo. Por el contrario, un intervalo es un conjunto de ondas y segmentos. En un electrocardiograma normal, los fenómenos eléctricos que causan la sístole y diástole auricular y ventricular, se manifiestan como una secuencia ordenada de ondas de características bien definidas, que por convención se designan como ondas *P*, *Q*, *R*, *S* y *T* (Figura 1).

A continuación se describen los aspectos característicos más importantes de las ondas normales de un ECG.

- **Onda P:** se produce por la despolarización de las aurículas. Esta onda se presenta como una deflexión positiva en la mayoría de las derivaciones. Su duración no supera los 120 ms, y su amplitud es menor a 0,25 mV. La repolarización de las aurículas comienza de 150 a 200 ms después de la finalización de la onda P.
- **Intervalo PQ o PR:** el intervalo PQ está constituido por la onda P y el segmento PR o PQ, y representa la despolarización auricular y la conducción a través del nodo aurículo-ventricular. Su duración es de entre 120 a 200 ms.
- **Complejo QRS:** es originado por la rápida despolarización de los ventrículos. Se trata del conjunto de ondas de mayor amplitud del ECG. Respecto a su duración, varía entre 80 y 100 ms.
- **Onda T:** representa la repolarización ventricular. Se trata de una onda positiva en la mayoría de las derivaciones del ECG. Su duración es de aproximadamente 150 ms y su amplitud no supera los 0,5 mV. Posee menor amplitud que el complejo QRS debido a que la despolarización es un fenómeno abrupto y de corta duración que ocurre casi simultáneamente en todas las fibras del miocardio ventricular, mientras que la repolarización es un proceso lento, que comienza entre 200 y 350 ms después del inicio del complejo QRS.
- **Intervalo QT:** representa los fenómenos eléctricos ocurridos durante toda la sístole ventricular. Su duración está fuertemente influenciada por la frecuencia cardíaca: a mayor frecuencia cardíaca menor duración del intervalo y viceversa; siendo su duración promedio de 400 ms.
- **Onda U:** su aparición es un fenómeno poco común en individuos sanos, aun así es posible encontrarla




Figura 2. Esquema general de las etapas de procesamiento

sin que la misma represente una afección cardíaca. Aunque su origen fisiológico es incierto, se supone que se debe a fenómenos de repolarización lenta o potenciales resultantes de fuerzas mecánicas en la pared ventricular.

- **Intervalo RR:** representa el conjunto de fenómenos eléctricos que transcurren durante un ciclo cardíaco y se define como todas las ondas y segmentos comprendidos entre el transcurso de una onda R y la siguiente. Los motivos por los cuáles se prefiere tomar al complejo QRS como marca de referencia para la determinación de la duración del ciclo cardíaco son facilidad de identificación e imposibilidad de no existencia.

III. PROCESAMIENTO DE LA SEÑAL DE ECG

Para clasificar los latidos procedentes de un ECG, es necesaria la manipulación del mismo para utilizar la información que contiene. Para ello, se realizan una serie de procesos, los cuáles pueden agruparse en tres etapas principales que son: *la detección de latidos*, *la extracción de características* y *su clasificación*. En la Figura 2 se muestra un diagrama en bloques de las etapas de procesamiento que se implementan en este trabajo.

En la etapa de detección, la señal se filtra para luego, mediante un algoritmo, detectar cada latido y segmentarlo individualmente. Posteriormente, se extraen características de estos latidos para luego ser clasificados mediante estrategias de inteligencia computacional. En las siguientes secciones se describen las técnicas empleadas para la realización de cada una de las etapas mencionadas.

III-A. Detección de latidos

Dependiendo de las condiciones de tiempo disponible para observar la señal de ECG, extraer los complejos QRS y clasificarlos, existen tres tipos de algoritmos de detección:

- **Algoritmo Off-line:** Son aquellos en los que se cuenta con toda la señal a analizar de antemano, pudiendo el algoritmo recorrer toda la señal sin restricciones.
- **Algoritmo On-line:** Son aquellos que trabajan sobre una señal que está siendo generada en ese momento, es decir que no pueden conocer la señal más allá de la última muestra que se recibió. Estos algoritmos tienen un margen entre dos y tres segundos para detectar los latidos, lo cuál les da la posibilidad de repasar la señal en caso de perderse un latido.
- **Algoritmos Real-Time:** Estos son similares a los On-line con la diferencia de que deben detectar cada latido antes de que llegue el próximo.

Cuando los filtros digitales son utilizados en tiempo real, muchos diseños de filtros se vuelven inadecuados debido al tiempo computacional requerido. Una considerable reducción de tiempo computacional se logra reemplazando los coeficientes de punto flotante por coeficientes enteros en las

ecuaciones de los filtros. Esto se debe a que al utilizar coeficientes enteros se evita la resolución de multiplicaciones de punto flotante reemplazándolas por instrucciones de suma y cambios de posición de bits. Estas instrucciones requieren menos ciclos de reloj que los cálculos de punto flotante. Por ello se selecciona el uso de filtros enteros.

III-A1. Filtros enteros: Los filtros enteros son una clase especial de filtro digital que tienen solamente coeficientes enteros en las ecuaciones que los definen. Esto conduce a algunas restricciones de diseño que a menudo puede hacer que sean difíciles de lograr características tales como una frecuencia de corte definida. Dado que los filtros enteros pueden operar a mayor velocidad que los diseños tradicionales, generalmente son el tipo de filtro adecuado cuando se utilizan microprocesadores lentos. Lynn [7] presentó la mejor técnica conocida para el diseño de filtros enteros. Se resume este método en dos pasos:

1. Se ubica un número de ceros igualmente espaciados alrededor del círculo unidad. Estos ceros atenúan completamente las frecuencias correspondientes a su ubicación.
2. El siguiente paso es elegir polos que también se encuentran en el círculo unidad, para eliminar algunos de los ceros.

Cuando un polo cancela un cero, la frecuencia correspondiente a su localización ya no es atenuada. Dado que cada punto en el círculo unidad representa una frecuencia, la localización de los polos y ceros determina la respuesta de frecuencia del filtro. Estos filtros son un tipo restringido de filtros recursivos. La forma general de la función de transferencia del filtro utilizada por Lynn es:

$$H_1(z) = \frac{[1 - z^{-m}]^p}{[1 - 2\cos(\theta)z^{-1} + z^{-2}]^t}$$

El exponente m representa cuántos ceros igualmente espaciados se encuentran alrededor del círculo unidad. El ángulo θ representa la posición angular de los polos. Las potencias p y t representan el orden de magnitud del filtro, el cuál tiene una relación directa con la ganancia y la atenuación de los lóbulos laterales. Aumentar p y t en cantidades enteras iguales tiene el efecto de poner filtros idénticos en cascada. Para que el filtro sea útil y físicamente realizable, p y t tienen que ser enteros positivos. Usando la función de transferencia anterior, podemos diseñar filtros pasa-bajo y pasa-altos.

Estos filtros tienen un beneficio agregado que es su característica de tener fase lineal, es decir, que todas las componentes en frecuencia de la señal sufren el mismo retraso en la transmisión a través del filtro. Esto es importante cuando se desea preservar el tiempo relativo de los picos y las características de la forma de onda de la salida.

III-B. Extracción de características

La etapa de extracción de características es clave para lograr la correcta clasificación de los latidos cardíacos. Cualquier información extraída del latido, utilizada para determinar su clasificación, puede ser considerada como característica. Entre las posibles técnicas de caracterización de los latidos se pre-seleccionaron las siguientes:

- *Transformada ondita (wavelet)*
- *Caracterización morfológica*

- *Análisis de Componentes Independientes (ICA)*
- *Enfoque no lineal y Teoría del caos*

La *transformada ondita* es una técnica de análisis de señales en los dominios temporal y de frecuencia, con la gran ventaja de poder realizar un análisis multi-resolución, es decir, mejorar la resolución temporal para determinadas bandas de frecuencia y mejorar la resolución en frecuencia para otras. Esta técnica se encuentra ampliamente utilizada en etapas de pre-procesamiento y clasificación de señales biológicas, y sus resultados son muy buenos, logrando un porcentaje de aciertos en la clasificación de latidos superior al 90% en los peores casos [20]. Sin embargo, su costo computacional es alto, por lo que se limita su aplicación a procesadores de altos recursos computacionales.

La *caracterización morfológica* trabaja en el dominio temporal utilizando características como las duraciones y amplitudes de las ondas P, R y T, y las duraciones de los intervalos RR de la señal de ECG. Si bien no requiere de muchos recursos computacionales, utilizar únicamente esta técnica resulta en porcentajes de aciertos muy bajos. Debido a que en la etapa de pre-procesamiento y detección se optó por sacrificar levemente la forma de la señal para ganar en velocidad de procesamiento, se decidió no utilizar las características morfológicas para la clasificación de latidos, pero sí se utilizarán las duraciones de los intervalos RR.

El *Análisis de Componentes Independientes (ICA)*, técnica que ha ganado popularidad en el campo del procesamiento de señales biomédicas, se utiliza generalmente cuando se requiere separar señales que han sido obtenidas a través de varios canales, en las componentes que la constituyen. Debido a su extensa utilización en otros campos, se desarrollaron algoritmos denominados "fastICA" que brindan la posibilidad de utilizar este análisis con bajos costos de procesamiento. En este trabajo se optó por utilizar esta herramienta en conjunto con el *Análisis de Componentes Principales* [18], la cuál se utiliza para reducir el número de características.

Durante los últimos años ha aumentado el número de análisis de señales electrocardiográficas con el *enfoque no lineal*. Se han propuesto diversas medidas no lineales para estimar la complejidad de una serie temporal. Algunas de ellas han sido aplicadas a las señales de ECG, como también a la variabilidad de la frecuencia cardíaca. Similar a la transformada ondita, si bien el enfoque no lineal presenta suficiente consistencia para la clasificación de señales, los altos costos computacionales requeridos para el cálculo de las características limita su aplicación a procesamiento off-line, es decir que no pueden aplicarse en tiempo real [19].

III-B1. Análisis de componentes principales: Un problema central en el análisis de datos multi-variables es la reducción de la dimensionalidad: si es posible describir con precisión los valores de p variables por un pequeño subconjunto $r < p$ de ellas, se habrá reducido la dimensión del problema a costa de una pequeña pérdida de información. El Análisis de Componentes Principales (PCA) tiene ese objetivo: dadas n observaciones de p variables, se analiza si es posible representar adecuadamente esta información con un número menor de variables construidas como combinaciones lineales de las originales. Por ejemplo, con variables con alta dependencia es frecuente que un

pequeño número de nuevas variables (menos del 20% de las originales) brinden más del 80% de la información que brindan las variables originales.

El análisis de componentes principales tiene doble utilidad: i) permite representar óptimamente en un espacio de dimensión pequeña observaciones de un espacio general p -dimensional. En este sentido, el análisis de componentes principales es el primer paso a identificar las posibles variables latentes, o no observadas que generan los datos. ii) Permite transformar las variables originales, en general correlacionadas, en nuevas variables no correlacionadas, facilitando la interpretación de los datos.

III-C. Clasificación

Para la clasificación se decidió utilizar Máquinas de Vectores de Soporte (SVM). Estas fueron derivadas de la teoría de aprendizaje estadístico postulada por Vapnik y Chervonenkis [21]. Las SVM fueron presentadas en 1992 y adquirieron fama cuando dieron resultados muy superiores a las redes neuronales en el reconocimiento de letra manuscrita, usando como entrada píxeles. SVM está ganando gran popularidad como herramienta para la identificación de sistemas no lineales debido a que está basado en el principio de minimización de riesgo estructural (SRM), el cuál ha demostrado ser superior al principio de minimización del riesgo empírico (ERM) utilizado por las redes neuronales [23]. Algunas de las razones por las que este método ha tenido éxito es que no posee mínimos locales y el modelo sólo depende de los datos que contienen más información, llamados vectores de soporte (SV). Las grandes ventajas que tiene SVM son:

- excelente capacidad de generalización debido a la minimización del riesgo estructurado.
- pocos parámetros a ajustar, el modelo sólo depende de los datos con mayor información.
- la estimación de los parámetros se realiza a través de la optimización de una función de costo convexa, lo cuál evita la existencia de un mínimo local.
- la solución de SVM es *sparse*, es decir, que la mayoría de las variables son cero en la solución de SVM, lo cuál significa que el modelo final puede ser escrito como una combinación de números muy pequeños de vectores de entrada, llamados vectores de soporte.
- lo anterior implica que la complejidad del clasificador depende de la cantidad de vectores que determinan la frontera y no de la dimensión del espacio.

SVM resuelve un problema cuadrático donde el número de coeficientes es igual al número de entradas o datos de entrenamiento. Este hecho hace que para grandes cantidades de datos, los métodos numéricos de optimización, existentes para resolver el problema cuadrático, no sean admisibles en términos computacionales. Éste es un problema que impide el uso de SVM para la identificación de sistemas no lineales en línea, esto es, en casos en los que las entradas son obtenidas de manera secuencial y el aprendizaje se realiza en cada paso.

III-C1. Clasificación por hiperplanos: Supongamos que hay m observaciones y cada una consiste en un par de datos:

- Un vector $x_i \in R^n$, $i = 1, \dots, m$
- Una etiqueta $y_i \in \{ +1, -1 \}$

Supóngase que se tiene un hiperplano que separa las muestras positivas (+1) de las negativas (-1). Lo que se quiere es definir hiperplanos que separen las muestras según sus etiquetas y_i . Cuando los datos no se pueden separar linealmente, se hace un cambio de espacio mediante una función ϕ que transforme los datos de manera que se puedan separar linealmente en el nuevo espacio. Este nuevo espacio también tiene definido un producto interno lo que permite, utilizando el llamado “kernel trick”, calcular el producto interno de la imagen de las muestras en el nuevo espacio de características utilizando funciones núcleo, sin tener que explicitar el mapeo que hace ϕ .

III-C2. SVM en problemas de clasificación de una clase: El algoritmo SVM es en general aplicado como un algoritmo de dos clases. Sin embargo, se presentan modificaciones a este algoritmo que permiten su aplicación a problemas donde sólo se busca establecer si una muestra pertenece o no a la clase con la cuál se ha entrenado [21], [22]. Estos métodos son usualmente conocidos como SVM de una clase (oc-SVM). Al igual que en SVM multi-clase, la idea es transformar el espacio de características a través de un kernel o núcleo. La diferencia en oc-SVM es que se trata al origen como el único miembro de la segunda clase. Luego utilizando parámetros de relajación se separa la imagen de la clase que nos interesa estudiar del origen utilizándose las técnicas estándar de SVM para dos clases. Si bien se han planteado diversos núcleos, los más comúnmente usados son: lineales, polinómicos, funciones de base radial (RBF), y sigmoideos.

Una vez elegido el núcleo adecuado, la estrategia es mapear los datos en el espacio de características correspondiente al núcleo y separarlos del origen con el mayor margen posible. Para un nuevo x , el valor $f(x)$ queda determinado evaluando de qué lado del hiperplano cae en el nuevo espacio de características. Debido a la variedad de núcleos posibles, este simple planteo geométrico se corresponde a una igual variedad de estimadores no lineales en el espacio de partida.

IV. IMPLEMENTACIÓN

Para la implementación del sistema propuesto, se utilizaron las librerías *fastICA* [13], [14], [15], [16], [17] y *LIBSVM* [24], [25] en MATLAB. Se utilizó además, la base de datos de arritmias del Massachusetts Institute of Technology y el Beth Israel Hospital (MIT-BIH) [11] disponible en www.physionet.org [12]. La misma está formada por 48 fragmentos electrocardiográficos de dos canales, de media hora de duración, extraídos de estudios ambulatorios con equipos Holter analógicos digitalizados a 360 muestras por segundo con una resolución de 11 bits sobre un rango de 10 mV (en el intervalo de -5 a 5 mV). El total de los latidos existentes fueron clasificados por cardiólogos, que además incorporaron información complementaria en los estudios, tales como anotaciones de ritmo, calidad de la señal, etc. Dado que las características de la señal electrocardiográfica dependen intrínsecamente de la derivación que se esté analizando, y a los fines de lograr una mayor uniformidad en el análisis realizado, se decidió trabajar únicamente con uno de los canales de cada estudio (ML II, Mason-Likar II).




Figura 3. Etapas de filtrado del detector QRS

IV-A. Detección de Complejo QRS

Pan y Tompkins desarrollaron un algoritmo de detección en tiempo real basado en el análisis de la pendiente de la señal en la banda de interés. Es decir, dada la señal de un ECG, se filtra en una banda de frecuencias conveniente y se analiza la señal extraída del filtro. El detector que se va a desarrollar se basa en este algoritmo [7], [8]. La Figura 3 muestra los distintos tipos de filtros involucrados en el análisis de la señal de ECG. Primero se diseñó un filtro pasa-banda desde un filtro entero que requiere solo coeficientes enteros. Como no es posible diseñar el filtro pasa-banda deseado con este enfoque, se reemplaza el mismo con uno en cascada de filtros pasa-bajo y pasa-alto. Este filtro aísla la energía predominante del complejo QRS centrada en 10Hz, atenuando las bajas frecuencias características de las ondas *P* y *T* y el corrimiento de línea de base, y también las altas frecuencias asociadas a ruido muscular e interferencia de línea (50 Hz).

El paso siguiente es la diferenciación, una técnica estándar para encontrar las pendientes altas que normalmente distinguen al complejo QRS de las otras ondas. Hasta este punto en el algoritmo, todos los procesos son realizados con filtros digitales lineales. Posteriormente sigue la transformación no lineal que consiste en elevar al cuadrado las muestras de la señal punto por punto. Esta transformación sirve para hacer todos los datos positivos antes de realizar la integración, y además para acentuar las altas frecuencias en la señal obtenida del proceso de diferenciación. Estas altas frecuencias son normalmente características del complejo QRS. La señal pasa por un integrador de ventana móvil. Este integrador suma el área debajo de la señal previamente elevada al cuadrado a través de un intervalo de 150 ms, avanza una muestra e integra la nueva ventana de 150 ms. Se elige un ancho de ventana lo suficientemente grande para incluir la duración de complejos QRS anormales extendidos, pero lo suficientemente corto para no solapar el complejo QRS con la onda *T*. Se aplican umbrales adaptativos a la señal integrada basados en una continua actualización de los picos estimados de señal y de ruido. Después de una detección, un proceso de toma de decisiones determina si el evento detectado es un complejo QRS o no.

IV-A1. Algoritmo de detección: Una vez procesada la señal, se debe determinar donde se ubica cada complejo QRS para las etapas de segmentación y caracterización. Para ello se utilizan umbrales adaptativos, según los cuáles se determina si un pico de energía corresponde a un complejo QRS o si se debe considerar como ruido. También se implementan en el algoritmo técnicas de búsqueda hacia atrás y determinación del pico *R*. Por cuestiones de espacio se omite el diagrama de flujo utilizado.

IV-B. Segmentación

Se optó por segmentar los latidos en ventanas centradas en el pico *R* de 201 muestras (100 muestras de cada lado). El

motivo de la elección es que de este modo es posible obtener muestras de la misma longitud que poseen el complejo QRS en la misma posición, lo que sería imposible si se segmentara en intervalos *RR*. La segmentación en ventanas centradas facilita considerablemente las etapas posteriores del proyecto integrador, además de brindar un mayor desempeño. El motivo de tomar 100 muestras de cada lado se debe a que de esta forma, el complejo QRS siempre queda incluido dentro del segmento y al mismo tiempo no se incluye la onda *T*. Se probó utilizar una ventana de mayor tamaño de manera que ésta sea incluida, pero los resultados obtenidos fueron peores que en el caso anterior.

IV-C. Extracción de características

Se utilizó la librería FastICA, la cuál implementa el algoritmo rápido de punto fijo. El primer planteo que se presenta es cuántas muestras se deben utilizar para encontrar las componentes independientes. Variando la cantidad de muestras, se observaron dos comportamientos. En uno de ellos, la precisión obtenida no varía significativamente a medida que se aumenta la cantidad de muestras; mientras que en el otro, la precisión va aumentando a medida que aumenta la cantidad de muestras alcanzando una meseta a partir de las cien muestras. De modo que se optó por utilizar cien muestras para la obtención de los componentes independientes.

El siguiente paso es determinar el número de componentes a utilizar. Éste debe ser lo menor posible dado que, a medida que aumenta su número, también aumenta la cantidad de procesamiento necesario. Para lograr la reducción de componentes utilizamos el Análisis de Componentes Principales sobre las muestras de los latidos. Se utilizaron dos criterios de selección. En primer lugar se realizó un gráfico de los valores propios y se seleccionaron componentes hasta que los restantes tengan similar valor. Y en segundo lugar, que las componentes seleccionadas posean más del 95 % de varianza. Se concluyó que la cantidad de componentes necesarios para obtener la mayor precisión posible depende de la cantidad de ruido que posea la señal, es decir que mientras más limpia sea la señal menos componentes se necesitarán, y si se utilizan más componentes de lo necesario, la precisión empieza a disminuir. Por ello se definió utilizar cinco componentes. Una vez seleccionado el número de componentes principales se realizó el Análisis de Componentes Independientes, obteniendo la matriz de mezcla y los componentes independientes.

IV-D. Clasificación de los latidos

Se utilizó la librería LIBSVM, y se usaron como núcleo funciones de base radial, lineal, polinómico y sigmoideo, para contrastar los resultados. Como parámetro de comparación se utilizó el porcentaje de aciertos de latidos anormales. La función de base radial demostró un superior desempeño frente a los otros tipos de núcleos. Una vez elegido el núcleo a utilizar, resta ajustar tres parámetros más. Primero hay que definir cuántas muestras de deben analizar para entrenar la SVM y posteriormente elegir las variables de configuración óptimas. Para definir la cantidad de muestras se corrió el programa, variando la misma, para un conjunto de registros. Se concluyó que a medida que aumenta el

número de muestras que se utiliza para el entrenamiento, también aumenta la precisión del modelo. Sin embargo, a partir de cierta cantidad, la media permanece casi constante mientras que la dispersión aumenta. Se decidió, entonces, utilizar 135 muestras para el entrenamiento de SVM.

V. RESULTADOS

V-A. Evaluación del desempeño del algoritmo

V-A1. *Detección de complejo QRS*: El desempeño del detector fue evaluado utilizando la base de datos del MIT-BIH Arrhythmia Database. Los resultados obtenidos se pueden observar en la Figura 4. Se tomaron al azar 27 registros con un total de 45594 latidos normales y 13731 latidos anormales (principalmente: contracción ventricular prematura, bloqueos de rama izquierda y derecha y contracción auricular prematura). Los resultados obtenidos se pueden observar en la Figura 4. Para comprender los resultados de esta evaluación se definen las siguientes clases de latidos:

- *TP: Verdaderos positivos (True Positive)* son los latidos correctamente detectados.
- *FP: Falsos positivos (False Positive)* son picos de la señal que el detector marcó erróneamente como latidos.
- *FN: Falsos negativos (False Negative)* son latidos que no fueron detectados.

Estas definiciones permiten calcular dos medidas del desempeño del detector:

- *Valor Predictivo Positivo (+P)*: Es una medida de cuántos de los latidos detectados son verdaderos.

$$+P = \frac{TP}{TP + FP}$$

- *Sensibilidad (S)*: Es una medida de cuántos latidos se detectan de entre todos los latidos analizados por el detector.

$$S = \frac{TP}{TP + FN}$$

En todas las clases de latidos definidas arriba, se tomaron separados los latidos normales y anormales con el objetivo de poder observar cómo se comporta la detección frente a ambos tipos.

Si se observan los resultados totales, el detector tuvo un muy buen desempeño logrando un 99.83 % de valor predictivo positivo y una sensibilidad del 99.74 %. Si se analiza esta última, separando los latidos normales de los anormales, las sensibilidades logradas son de 99.98 % y 98.96 % respectivamente. A simple vista hasta el peor de los resultados, que es la sensibilidad de los latidos anormales, se puede considerar como bueno ya que de 100 latidos analizados se perdería uno sólo. Sin embargo, si se analiza cada registro por separado se puede observar que para algunos de ellos el detector tuvo un rendimiento muy pobre llegando a tener un 0 % de sensibilidad para los latidos anormales.

Dichos registros se analizaron detalladamente para poder detectar cuál es el motivo por el cual el desempeño disminuye tanto. Se determinó que el algoritmo es más propenso a fallar cuando se da alguna de las siguientes condiciones:

- En los cambios de ritmo bruscos suele perder de uno a tres latidos hasta acondicionarse.

- Alternancia entre latidos normales y contracciones ventriculares prematuras con frecuencias altas.
- Cuando hay una contracción ventricular prematura entre dos latidos normales y el intervalo R-R entre estos dos últimos se asemeja al R-R promedio.
- Cuando el registro presenta contracciones auriculares prematuras aberrantes.

V-A2. *Clasificación de los latidos*: Para la comprobación de la técnica estudiada se emplearon 26877 latidos de los cuáles 20500 corresponden a latidos sanos y 6377 corresponden a latidos patológicos. Se utilizaron registros con diferentes tipos de patologías y niveles de ruido, no agregado, para poder observar cómo se desempeña el algoritmo en diversos ambientes. En el conjunto de latidos “normales” se agruparon latidos sanos, latidos generados por marcapasos externos implantables y latidos con bloqueo de rama; y el conjunto de latidos “anormales” está formado por las siguientes patologías: contracción ventricular prematura (C.V.P), contracción auricular prematura (C.A.P), contracción nodal prematura (C.N.P), latidos inclasificables (Q) y fusión entre CVP y latido normal (F). Los resultados obtenidos se muestran en la Figura 5, donde el porcentaje de aciertos medio es el promedio de los porcentajes de aciertos de los registros analizados, y el rango muestra el peor y el mejor porcentaje obtenido, respectivamente. Si desglosamos el desempeño de los latidos anormales en las distintas patologías analizadas, los resultados son los que se indican en la Figura 6.

Si se analizan los datos de manera general, o sea trabajando con promedios, y considerando que del 100 % de los latidos de cada registro, tan sólo un 7,5 % corresponde a latidos anormales, la implementación de este algoritmo en dispositivos de monitoreo móviles permite un ahorro de memoria, o de transmisión de datos según el caso, de un 63,83 %. En la Figura 7 se muestran los ahorros obtenidos para algunos de los registros analizados.

El registro 205 tuvo el peor desempeño de todos los registros analizados, consiguiendo un ahorro del 48,35 %. A éste le sigue el registro 115, que no se encuentra en la tabla anterior, que consiguió un ahorro del 50 %. Traduciendo estos resultados a este caso particular, considerando el caso de almacenamiento y no el de transmisión, tener un ahorro del 48,35 % significa que se logra casi duplicar la capacidad de almacenamiento sin necesidad de hacer cambios de hardware.

V-B. Influencia del ruido en la señal

V-B1. *Influencia del ruido en la detección*: Para analizar la robustez del algoritmo frente al ruido, se agregó ruido gaussiano con distintas relaciones señal/ruido (SNR) a las señales originales. Por ejemplo, una SNR igual a 10 equivale a una señal con una amplitud 10 veces mayor respecto al ruido agregado. En la Figura 8 se pueden observar los resultados. El algoritmo de detección mostró un buen desempeño frente al ruido, logrando los mismos resultados que los obtenidos con la señal original, hasta con una SNR igual a 5. Para valores menores a 5, el algoritmo comienza a fallar detectando ruido como si fuese un latido.

V-B2. *Influencia del ruido en la clasificación*: Al igual que con la etapa de detección, se pretendió estudiar como es

registro	cantidad latidos		TP		FN		FP	+P	S		
	normales	anormales	normales	anormales	normales	anormales			normales	anormales	total
100	2237	34	2237	34	0	0	0	100.00%	100.00%	100.00%	100.00%
101	1859	5	1854	1	1	0	4	99.78%	99.95%	100.00%	99.95%
102	2127	60	2127	60	0	0	0	100.00%	100.00%	100.00%	100.00%
103	2081	2	2080	2	1	0	0	100.00%	99.95%	100.00%	99.95%
104	1542	686	1514	657	0	1	28	98.73%	100.00%	99.85%	99.95%
105	2525	46	2482	4	1	0	42	98.34%	99.96%	100.00%	99.96%
106	1507	520	1507	488	0	32	0	100.00%	100.00%	93.85%	98.42%
107	2077	58	2077	57	0	1	0	100.00%	100.00%	98.28%	99.95%
109	0	2530	0	2526	0	4	0	100.00%	-	99.84%	99.84%
112	2536	2	2536	2	0	0	0	100.00%	100.00%	100.00%	100.00%
113	1787	6	1787	6	0	0	0	100.00%	100.00%	100.00%	100.00%
115	1952	0	1952	0	0	0	0	100.00%	100.00%	-	100.00%
116	2301	110	2295	110	2	0	4	99.83%	99.91%	100.00%	99.92%
117	1533	1	1533	1	0	0	0	100.00%	100.00%	100.00%	100.00%
118	0	2277	0	2277	0	0	2	99.91%	-	100.00%	100.00%
122	2475	0	2475	0	0	0	0	100.00%	100.00%	-	100.00%
123	1514	3	1514	0	0	3	0	100.00%	100.00%	0.00%	99.80%
124	0	1618	0	1611	0	7	0	100.00%	-	99.57%	99.57%
200	1743	857	1739	856	0	1	4	99.85%	100.00%	99.88%	99.96%
201	1624	338	1624	278	0	60	0	100.00%	100.00%	82.25%	96.94%
202	2061	75	2061	67	0	8	0	100.00%	100.00%	89.33%	99.63%
203	2528	445	2509	427	4	18	15	99.49%	99.84%	95.96%	99.26%
205	2570	85	2568	82	2	3	0	100.00%	99.92%	96.47%	99.81%
209	2620	384	2619	384	0	0	1	99.97%	100.00%	100.00%	100.00%
214	0	2261	0	2257	0	4	2	99.91%	-	99.82%	99.82%
219	2081	72	2081	72	0	0	0	100.00%	100.00%	100.00%	100.00%
231	314	1256	314	1256	0	0	0	100.00%	100.00%	100.00%	100.00%
total	45594	13731	45485	13515	11	142	102	99.83%	99.98%	98.96%	99.74%

Figura 4. Desempeño del detector en la base de datos del MIT-BIH

Tipo de latidos	Porcentaje de aciertos	
	Medio	Rango
Latidos Normales	69,42 %	50 % - 86 %
Latidos Anormales	98,93 %	88 % - 100 %

Figura 5. Desempeño del algoritmo.

Patología	Porcentaje de aciertos
C.A.P	86,98 %
C.V.P	99,69 %
C.N.P	95,52 %
Q	100 %
F	100 %

Figura 6. Porcentaje de aciertos discriminado en patologías.

el comportamiento del algoritmo en la etapa de clasificación frente al ruido. Se procedió de similar manera que en la sección anterior y los resultados obtenidos se muestran en la Figura 9. Para señales con una SNR mayor a 10 el algoritmo tiene el mismo desempeño que con las señales originales. A partir de señales con RSR menores a 10 el desempeño disminuye rápidamente, siendo muy bajo para SNR menores que 5.

Registro	ALN*	ALA*	Ahorro memoria/transmisión
100	72 %	94,11 %	70,91 %
101	62 %	100 %	61,83 %
102	86 %	98,74 %	84,57 %
106	86 %	99,42 %	56,32 %
123	86 %	100 %	85,83 %
201	77 %	99,65 %	60,98 %
203	63 %	99,77 %	51,91 %
205	50 %	100 %	48,35 %
219	67 %	93,05 %	64,68 %

*ALN: Aciertos latidos normales; ALA: Aciertos latidos anormales

Figura 7. Ahorro de memoria/transmisión.

Relación señal/ruido*	Porcentaje de aciertos
100	100 %
50	100 %
25	100 %
10	100 %
5	100 %
2	55 %
1	37 %

*medido linealmente

Figura 8. Influencia del ruido en la detección.

V-C. Prueba de Concepto

Debido a que el desarrollo se realizó de manera off-line, es decir, se utilizó todo el registro entero del ECG, una vez

Relación señal/ruido*	Porcentaje de aciertos
100	100 %
50	100 %
25	100 %
10	96 %
5	70 %
2	16 %
1	6 %

*medido linealmente

Figura 9. Influencia del ruido en la clasificación.

obtenidos los resultados se procedió a adaptar el algoritmo para su implementación en tiempo real. Para realizar la prueba de concepto se utilizó Simulink de MATLAB y en consecuencia, la adaptación no requirió una migración del lenguaje de programación utilizado ya que Simulink es compatible con la mayoría de las funciones definidas en MATLAB.

Como señales de entrada se utilizaron los mismos registros de la base de datos del MIT-BIH. Por lo tanto, el primer paso fue configurar la entrada para que lea los registros una muestra a la vez, simulando un sistema de adquisición de tiempo real. De esta forma, en un instante determinado no se conocen los valores futuros y, salvo que se hayan guardado en un buffer, se pierden los valores anteriores.

La prueba de concepto consta de dos modelos realizados en Simulink, uno para el entrenamiento (Figura 10), otro para la clasificación (Figura 11), y un código en MATLAB que recibe los datos del modelo de entrenamiento, les aplica el Análisis de Componentes Independientes y entrena a la Máquina de Vectores de Soporte. Una vez realizado el entrenamiento, los valores obtenidos son enviados al modelo de clasificación para, como su nombre lo indica, proceder a clasificar los latidos. Este procedimiento puede observarse con más detalles a continuación. Se presenta, con un ejemplo, la realización de la simulación de la prueba de concepto. Primero se seleccionó un registro que posee todos los latidos normales.

Ese registro, modificado para ser simulado como si fuera en tiempo real, se utiliza como entrada del modelo de entrenamiento. Éste detecta y guarda los 200 primeros latidos con sus respectivos valores de intervalo RR, que es la cantidad de latidos necesarios para realizar el entrenamiento de la SVM. En las siguientes ilustraciones se muestran, primero los latidos segmentados que luego son enviados a MATLAB y en segundo lugar, el esquema del modelo de entrenamiento.

Una vez obtenidos los primeros 200 latidos se ejecuta el código desarrollado en MATLAB con lo que obtenemos los vectores de soporte y otros parámetros extraídos de SVM que nos permitirán clasificar los latidos que se vayan detectando. Con estos datos es posible correr el modelo de clasificación que, a medida que detecta un latido, lo clasifica e incrementa un contador dependiendo si éste fue clasificado como normal o anormal. A continuación se muestra el esquema de este modelo. El bloque de pre-procesado es idéntico al 80 del modelo anterior, y el bloque "detector" es similar al de "entrenamiento", de modo que estos dos bloques no se muestran.

Al correr el modelo de clasificación con el mismo registro utilizado para el entrenamiento, se obtuvieron de los 170

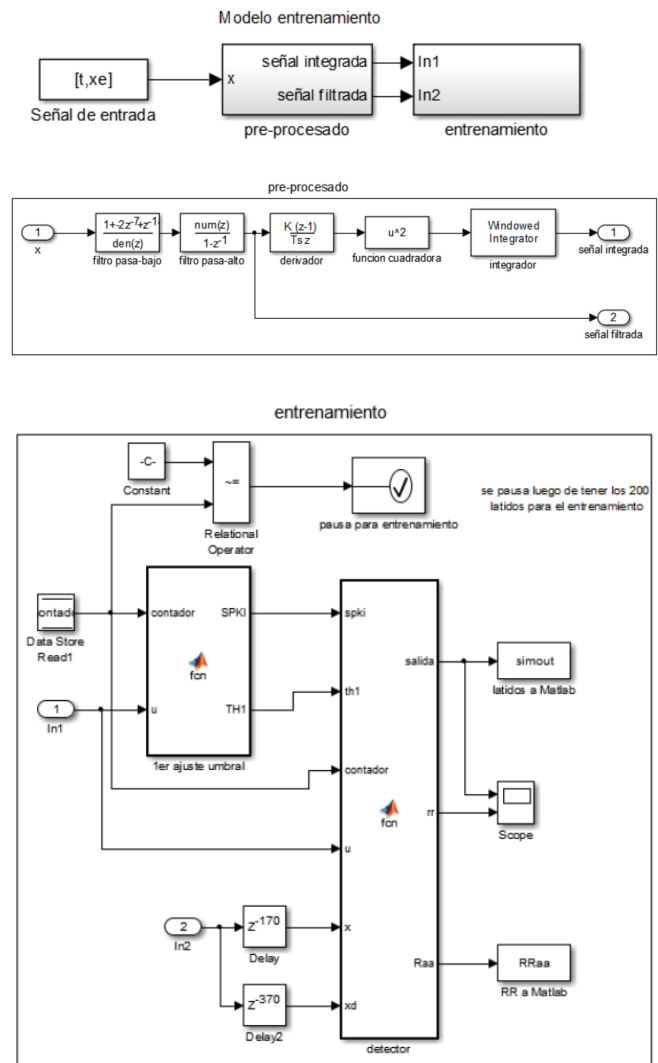


Figura 10. Modelo de entrenamiento.

latidos clasificados, 32 fueron mal clasificados debido a que todos eran normales. Por lo tanto el porcentaje de acierto fue del 76,8 %. A continuación, se corrió de nuevo el modelo de clasificación pero utilizando como entrada, un registro que posee latidos generados por un marcapasos externo implantable. Todos los latidos fueron clasificados correctamente ya que ninguno era normal. Con estas dos simulaciones se puede observar también lo que se planteó a lo largo del trabajo, que es más relevante la clasificación correcta de latidos anormales, aunque esto produzca una disminución del desempeño del clasificador.

VI. CONCLUSIONES

En el presente trabajo se muestra la implementación de un algoritmo de detección de complejos QRS on-line que posee un buen desempeño y que no requiere de grandes recursos computacionales. Mediante la utilización del Análisis de Componentes Independientes se obtuvo un número reducido de características, cinco obtenidas con ICA y tres con duraciones de los intervalos RR. Debido a esto, se limita el clasificador a uno de tipo binario, es decir que sólo puede diferenciar entre latidos normales y anormales, no pudiendo distinguir entre las diversas patologías que puedan

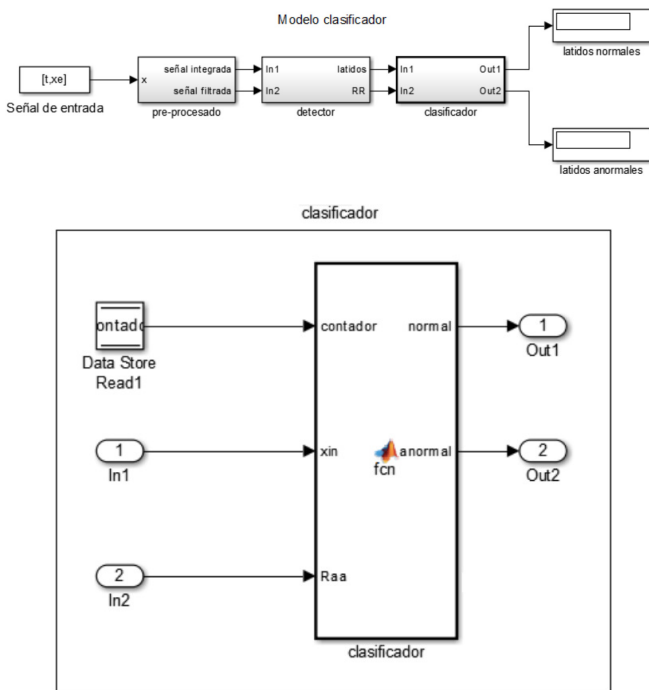


Figura 11. Modelo de clasificación.

presentarse. Este hecho no representa un problema, ya que el objetivo de este trabajo es reducir la cantidad de información transmitida o almacenada, dejando el diagnóstico de la patología a un especialista. Cabe resaltar que, según los antecedentes encontrados, los trabajos similares de clasificación binaria utilizan más del doble de características y consiguen simplemente un porcentaje de aciertos un poco mayor [27]. Por otro lado, se encontraron trabajos de clasificación multi-clase con un desempeño superior pero utilizan gran cantidad de características, y todos ellos son para implementación off-line [20], [10], [26].

Gracias a las Máquinas de Vectores de Soporte de una clase, se evitó la necesidad de disponer de grandes bases de datos para el entrenamiento de la red. Otra ventaja importante es que puede ajustarse el considerado latido “normal” a cada paciente, incluso si este latido presenta alguna patología que se desee omitir durante el estudio, como por ejemplo, el uso del marcapasos. En cuanto a los resultados obtenidos, se llega a las siguientes conclusiones:

- El algoritmo alcanzó una precisión media de casi 70 % permitiendo un ahorro de memoria, o de transmisión de datos, de un 64 %, teniendo como peor resultado un ahorro del 48 %, logrando un porcentaje de aciertos medio del 99 %.
- La patología que más inconvenientes presenta al ser clasificada es la contracción auricular prematura. Esto se debe a la similitud que posee con un latido sano.
- Se obtuvo una buena robustez del algoritmo frente al ruido presente tanto en la etapa de detección como en la de clasificación.

Finalmente, se logró realizar una prueba de concepto del sistema desarrollado en Simulink, demostrando que éste podría ser utilizado en aplicaciones de tiempo real.

Como trabajo futuro, se propone la implementación en un sistema de adquisición portátil con microprocesador o en

téléfonos inteligentes, y utilizarlo para monitorizar pacientes y deportistas de alto rendimiento con el fin de enviar alarmas al servicio de emergencia al detectarse una anomalía, y enviar información del registro electrocardiográfico para analizar la patología.

REFERENCIAS

- [1] E. Gonzalez; F. Cagnolo; C. Olmos; C. Centeno; G. Riva; C. Zerbini. *Medical Data Transmission System for Remote Healthcare Centres*, Journal of Physics: Conference Series, Volume 90, Issue 1, article id. 012029, 8 pp. (2007)
- [2] G. Riva; C. Zerbini; J. Voos; C. Centeno; E. Gonzalez. *Low Level Communication Management for e-Health Systems*, SABI 2011, Mar del Plata, Buenos Aires, 2011.
- [3] T. Jeon; B. Kim, M. Jeon; B. Lee. *Implementation of a Portable Device for Real-Time ECG Signal Analysis*. BioMedical Engineering OnLine, 201413:160, 2014.
- [4] W. F. Ganong. *Fisiología Médica*. Mc Graw Hill, 23 Ed. México, 2010.
- [5] C. Guyton; J. E. Hall. *Tratado de Fisiología Médica*. Elsevier, 12 Ed. Madrid, 2011.
- [6] N.V. Thakor; J.G. Webster; W.J. Tompkins. *Optimal QRS detection*. Medical and Biological Engineering, pages 343–350, 1983.
- [7] W.J. Tompkins; V.X. Afonso. *Biomedical Digital Signal Processing: C-Language Examples and Laboratory Experiments for the IBM PC*. Chapter 12, pages 236–264. Englewood Cliffs, NJ: Prentice-Hall, 1993.
- [8] J. Pan; W.J. Tompkins. *A Real-Time QRS Detection Algorithm*. IEEE Trans. Biomed. Eng., BME-32:230–236, 1985.
- [9] P. Aguirre; J. Cardelino; N. Loeff. *Cardident sistema de detección, clasificación e identificación en línea de complejos QRS*. Universidad de la República, Montevideo, Uruguay, 2002.
- [10] J.A. Fischer. *Caracterización de Electrocardiogramas mediante Redes Neuronales y Transformada Ondita*. FCFEYN, Universidad Nacional de Córdoba, Córdoba, Argentina, 2014.
- [11] Moody GB, Mark RG. *The Impact of the MIT-BIH Arrhythmia Database*. IEEE Eng in Med and Biol 20(3):45-50 (May-June 2001). (PMID: 11446209)
- [12] Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng C-K, Stanley HE. *PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals*. Circulation 101(23):e215-e220 [http://circ.ahajournals.org/cgi/content/full/101/23/e215]; 2000.
- [13] A. Hyvarinen; E. Oja. *A Fast Fixed-Point Algorithm for Independent Component Analysis*. Helsinki University of Technology, Finlandia, 1997.
- [14] A. Hyvarinen; E. Oja. *Independent Component Analysis: Algorithms and Applications*. Neural Networks Research Centre. Helsinki University of Technology. 2000.
- [15] A. Hyvarinen; J. Karhunen; E. Oja. *Independent Component Analysis*. John Wiley and sons, inc. 2001.
- [16] A. Hyvarinen. *Fast and Robust Fixed-Point Algorithms for Independent Component Analysis*. Neural Networks Research Centre. Helsinki University of Technology. 1999.
- [17] Y. Wu; L. Zhang. *ECG Classification Using ICA Features and Support Vector Machines*. Department of Computer Science and Engineering, Shanghai University. China, 2011.
- [18] T. Jolliffe. *Principal Component Analysis*. 2 Ed. Springer. UK, 2002.
- [19] E. Delgado Trejos. *Ventricular Arrhythmia Detection Using Non-linear Dynamics Techniques on ECG Signals*. Universidad Nacional de Colombia. Colombia, 2003.
- [20] E. J. da Silva Luz; W. R. Schwartz; G. Cámara Chávez; D. Menotti. *ECG-based Heartbeat Classification for Arrhythmia Detection: A Survey*. Computers methods and programs in biomedicine, 2015.
- [21] A. Reyna. *SVM de una Clase: Aplicación a Detección de Novedad*. IIE, FING, 2009.
- [22] L. M. Manevitz. *One-Class SVMs for Document Classification*. Department of Computer Science, University of Haifa. Israel, 2001.
- [23] C. Bishop. *Pattern Recognition and Machine Learning*. Springer, N. Y., 2005.
- [24] C. Chang; C. J. Lin. *LIBSVM: LIBSVM – A Library for Support Vector Machine*. ACM Transactions on Intelligent Systems and Technology, 2011. www.csie.ntu.edu.tw/~cjlin/libsvm/
- [25] C. Chang; C. J. Lin. *A Practical Guide to Support Vector Classification*. Department of computer Science; National Taiwan University, Taipei, Taiwan. Last updated, may 19, 2016.
- [26] P. de Chazar. *Automatic Classification of Heartbeats Using ECG Morphology and Heartbeat Interval Features*. IEEE Transactions on Biomedical Engineering, Vol. 51, July 2004.
- [27] G. Bortolan; I. I. Christov; W. Pedrycz. *Hiperbox Classifiers for ECG Beat Analysis*, in: Computers in Cardiology, 2007.