

Cardiac Arrhythmia Classification based on the RMS Signal and Cyclostationarity

N. Gómez and M. Noriega

Abstract— The goal of this paper is to present a method of classification for cardiac arrhythmias. This method is based on the analysis of the (RMS) signal extracted from the electrocardiogram (ECG) leads and the heart beat cyclostationarity nature. The coefficients of spectral correlation function are useful in order to differentiate among the five types of beats: Normal (N), Premature Ventricular Contraction (PVC), Premature Atrial Contraction (APC), Left Bundle Branch Block (LBBB) and Right Bundle Branch Block (RBBB). Some simple statistical measures for spectral correlation coefficients are extracted while Principal Component Analysis (PCA) is used to reduce its features. Finally, the classification using Artificial Neural Networks (ANNs) is implemented. Two experiments were performed, one that used a multi-lead ECG signal, and the other that used the RMS signal as input. These experiments showed that when using the RMS signal better results are obtained. This last method led to some specific results: sensitivity, specificity and accuracy indexes of 97.68%, 99.08% and 98.72%, respectively.

Index Terms—Arrhythmia, Electrocardiogram, RMS signal, Cyclostationarity, Spectral correlation.

I. INTRODUCCIÓN

Las enfermedades cardíacas son unas de las principales causas que conducen a la muerte, por tal motivo requieren de eficientes técnicas de reconocimiento y detección. Según la Sociedad Americana del Corazón (American Heart Association), la primera causa corresponde a las enfermedades cardiovasculares [1]. Las arritmias cardíacas constituyen gran parte de las patologías médicas detectadas en las consultas de cardiología. La asistencia a estas, que pueden ser asintomáticas, es tarea vital en los servicios médicos, ya sea como complicaciones de enfermedades anteriormente diagnosticadas o como ayuda en la prevención de otras. El diagnóstico se realiza por el personal médico, mediante el reconocimiento de morfologías y criterios sobre el electrocardiograma. Si bien existen diversas metodologías para llevar a cabo dicha evaluación y diagnóstico, varios estudios han mostrado que carecen de reproducibilidad debido al carácter subjetivo tanto de los criterios, como del juicio médico [2].

En el caso de monitorio ambulatorio o cuando los pacientes se encuentran hospitalizados, el carácter subjetivo de los criterios de diagnósticos se incrementa porque el médico tiene que examinar largas grabaciones de ECG. Además a esto se le añade que algunas arritmias no aparecen continuamente en el

ECG de corta duración, por lo que la detección y diagnóstico temprano de estas se enmarca como una tarea de vital importancia en la actualidad. Para aliviar esta carga, los sistemas asistidos por computadora (CAD Computer Aided Diagnosis) se usan para diagnosticar automáticamente arritmias cardíacas.

En la literatura especializada se reportan varias metodologías para la detección de arritmias, las cuales se evalúan principalmente a partir de los índices de desempeño exactitud, especificidad y sensibilidad. Para el reconocimiento de los latidos, algunas se basan en características morfológicas del electrocardiograma como la presentada por Gothwal et al. [3] y Zhang et al. en [4]. Pal et al. en [5] proponen un método a partir de la morfología de la onda en términos de un factor forma y de la amplitud del pico R. García et al. en [6] combinan características temporales y morfológicas.

Algunas metodologías también se han basado en la transformada Wavelet tanto para el pre-procesamiento como para los módulos de extracción de características [7], [8], [9], [10], [11], [12]. Otros ejemplos utilizan otras transformadas, mediante la transformada coseno discreta y análisis de componentes principales como método de extracción de características y para la clasificación redes neuronales probabilísticas, Martis et al. en [13] logran resultados notables.

Las características no lineales de la señal de ECG también se han utilizado para discriminar entre los latidos cardíacos. Acharya et al. las utilizan para clasificar 4 tipos de latidos cardíacos [14] y Hajeb-Mohammadipour et al. manejan además características de frecuencia y tiempo [15]. Por otro lado, Elhaj et al. [16] combinan tanto características lineales como no lineales y Rajesh et al. [17] introducen la clasificación a partir de métodos de descomposición no lineales mediante EEMD (Ensemble empirical mode decomposition), y EMD (Empirical mode decomposition).

Las técnicas espectrales de orden superior se han introducido como una solución para la clasificación de arritmias, Martis et al. en [18] utilizan características no lineales de espectro de orden superior para diferenciar los latidos del ECG. Las características del espectro de segundo orden se someten a análisis de componentes independientes (ICA) para la reducción de datos. Nanjundegowda et al. en [19] también utilizan ICA y espectro de orden superior.

Los algoritmos de aprendizaje profundo (Deep Learning), se muestran también representativamente [19], [20], [21], [22]. La propuesta realizada por Kutlu et al. en [23] donde se clasifican latidos cardíacos basados en el estándar ANSI/AAMI, se apoya en la forma de onda del ECG y en

N. Gómez, Universidad de Oriente, Santiago de Cuba, Cuba, ngomez@uo.edu.cu

M. Noriega, Universidad de Oriente, Santiago de Cuba, Cuba, mnoriega@uo.edu.cu

DBN (Deep Belief Networks). Altan et al. en [24] utilizan características de la forma de onda y SODP (Second Order Difference Plot) con la misma técnica para la etapa de clasificación. Acharya et al. [25] utilizan señales de ECG de 2 y 5 segundos de duración sin detección del complejo QRS y una red neuronal convolucional.

Los registros de ECG pueden ser afectados por distintos tipos de ruidos de forma general: ruido electromiográfico, ruido introducido por los dispositivos electrónicos, interferencias de la línea eléctrica, ruido de contacto del electrodo, artefactos de movimiento, derivas de línea base y el ruido electroquirúrgico [26]. Los métodos de clasificación de arritmias cardíacas y de detección de puntos característicos en el ECG más sofisticados fallan en presencia de estos y provocan falsos positivos y falsos negativos en el sistema de clasificación. Debido a que estos tipos de ruidos limitan la utilidad del ECG para estos sistemas de detección de arritmias, sobre todo en el ECG ambulatorio, resulta necesaria su eliminación o reducción para una mejor evaluación clínica.

La mayoría de las metodologías anteriores se basan en tres etapas principales: pre-procesamiento, extracción de características y clasificación. En algunos, la extracción de características se realizan directamente del tiempo o la representación en frecuencia de la señal, en los métodos que utilizan algoritmos de aprendizaje profundo el enfoque cambia, las características son extraídas por el propio algoritmo. Se destaca además que solo trabajan con una sola derivación o canal de los disponibles en la base de datos que utiliza para la experimentación, o no queda claramente especificado.

De esto se deriva que a pesar del rendimiento logrado el sistema de clasificación solo toma en cuenta un enfoque parcial del fenómeno cardíaco debido a que se entrena para una sola derivación de ECG. La señal electrocardiográfica puede interpretarse de acuerdo a la derivación con la que es captada, ya que cada una de estas, representa la lectura de la magnitud y dirección de los vectores del potencial de acción desde distintos lugares de referencia [27], [28]. Aplicando un nuevo enfoque para las metodologías anteriores basado en la creación de una nueva señal más robusta a partir de la combinación de un grupo de derivaciones en sentido RMS [29], se puede obtener una metodología de clasificación menos dependiente de la derivación escogida y que aumente los índices de desempeño del sistema de clasificación de latidos.

En la práctica, existe una gran variedad de procesos que pueden modelarse a partir de un origen periódico. Independientemente de que algunos de estos procesos no se definan explícitamente como una función periódica en el tiempo, sus parámetros estadísticos sí pueden variar de forma periódica. Estos procesos se conocen como procesos cicloestacionarios [30].

El uso de procesos cicloestacionarios abarca una amplia gama de aplicaciones que van desde las comunicaciones y el procesamiento de señales, hasta la economía, la ingeniería biomédica, el modelado de fenómenos atmosféricos, entre otros [30], [31], [32]. Un resumen extenso de la aplicabilidad de las propiedades de cicloestacionaridad puede encontrarse en [31]. Los autores clasificaron alrededor de 21 áreas de

aplicación de estos conceptos en el procesamiento de datos.

Es imposible realizar tareas de análisis espectral, detección y estimación de señales que involucren no estacionariedad generalmente desconocidas, cuando solo hay un registro de datos disponible. Solo la no estacionariedad estructurada se pueden manejar cuando hay variaciones rápidas; y solo para clases de procesos no estacionarios con parámetros finitos se pueden calcular descriptores estadísticos confiables usando una sola serie de tiempo. Una de esas clases es la de los procesos cicloestacionarios (en sentido amplio) que se caracteriza por la periodicidad que exhibe en su media y correlación [33]. Partiendo de que la cicloestacionariedad está asociada a un evento de naturaleza periódica, en [34] la hipótesis de uso se dirige a aplicaciones en el sistema cardiovascular teniendo en cuenta la naturaleza cíclica o comportamiento rítmicos de los latidos del corazón.

El método propuesto clasifica cinco tipos de latidos cardíacos utilizando un nuevo enfoque basado en la creación de una nueva señal a partir de la combinación de un grupo de derivaciones en sentido RMS, y la propiedad de correlación espectral de los procesos cicloestacionarios. Con la primera se logra un enfoque total del fenómeno cardíaco y con la segunda un modelado real de la señal al asumir que esta no es estacionaria. Con esta última se obtiene la ventaja de excluir el efecto del ruido estacionario [32], [35], que no posee naturaleza cíclica, con lo que se obtendría gran ventaja en la disminución del nivel de complejidad del sistema.

II. MATERIALES Y MÉTODOS

El método propuesto clasifica cinco tipos de latidos: normal, contracción auricular prematura, contracción ventricular prematura, bloqueo de rama izquierda y bloqueo de rama derecha; N, APC, VPC, LBBB y RBBB, respectivamente; por su término en inglés (Normal, Premature Atrial Contraction, Premature Ventricular Contraction, Left Bundle Branch Block y Right Bundle Branch Block). El bloque fundamental de la metodología consiste en la extracción de características para la posterior etapa de clasificación a través de la señal de ECG RMS y del análisis de señales cicloestacionarias mediante la estimación de la función de correlación espectral. En la Fig. 1 se ilustra el método propuesto.

El método se evalúa con un conjunto de latidos de ECG multiderivación como se indica en el diagrama, para tratar de aprovechar la robustez de la señal en sentido RMS a partir de la combinación de un grupo de derivaciones. A modo de comparación, se realiza otra experimentación con un conjunto de latidos provenientes de las dos derivaciones con que cuanta la base de datos y no se realiza el bloque de extracción de la señal RMS. Los coeficientes de correlación espectral que se extraen de cada latido en el segundo bloque se representan como una matriz de coeficientes.

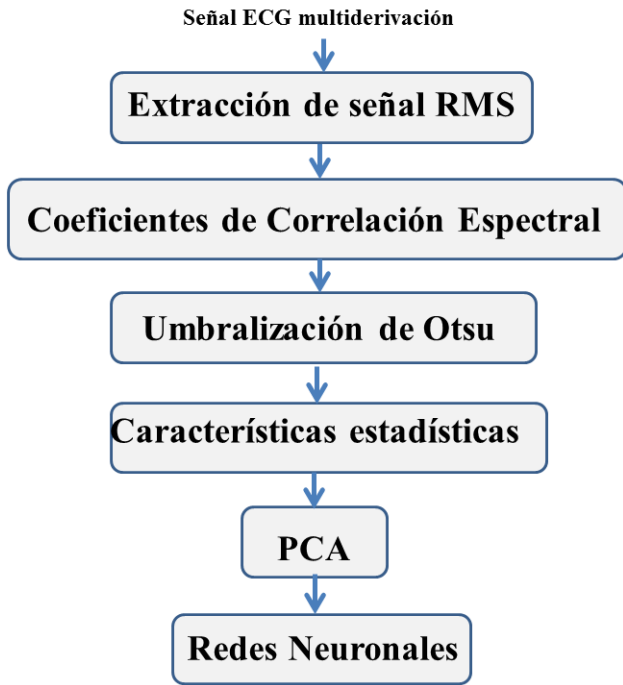


Fig. 1. Diagrama en bloques del método propuesto.

Gran parte de los coeficientes de las matrices de correlación espectral son cero. Por tal motivo, en la próxima etapa se trata cada matriz como una imagen a umbralizar utilizando el método de Otsu, para recortar cada una en imágenes más pequeñas y así minimizar los gastos innecesarios de procesamiento. Luego se obtienen características estadísticas de cada una de las matrices de los coeficientes. Para reducir el espacio de características se utiliza Análisis de Componentes Principales PCA (Principal Component Analysis). Por último se utiliza redes neuronales para realizar la clasificación.

A. Señal RMS del ECG Multiderivación.

Este enfoque para los experimentos anteriormente descritos, parte de la creación de una nueva señal a partir de la combinación de un grupo de derivaciones $x_i[n]$ en sentido RMS (Root Mean Square)[29] dado por:

$$x[n] = \sqrt{\frac{1}{M} \sum_{i=1}^M x_i^2[n]} \quad (1)$$

Siendo M el tamaño del grupo y n cada valor discreto de la señal. Dicho grupo debe ser o bien las 12 derivaciones estándar (12L) o las 3 derivaciones ortogonales de Frank (3L), siendo el único requisito que la remoción del movimiento de línea de base se realice previamente en cada $x_i[n]$. Las variaciones de la línea base se producen debido a múltiples factores, como por ejemplo, al movimiento del paciente durante la adquisición del electrocardiograma, la respiración y cambios en la impedancia de los electrodos. Estas variaciones suponen una interferencia de baja frecuencia y de cierta amplitud que deben ser reducidas para no alterar el resultado de procesos posteriores.

La señal resultante debe revelar cómo surgen nuevas

morfologías en $x[n]$ como resultado de la integración RMS de las diferentes proyecciones eléctricas en todas las derivaciones de un grupo. En la Fig. 2 se muestra la obtención de la señal RMS a partir de las 2 derivaciones disponibles en la base de datos. Como puede verse en la señal de ECG RMS surge una nueva morfología como consecuencia de la integración RMS de las diferentes proyecciones eléctricas en las derivaciones de un grupo.

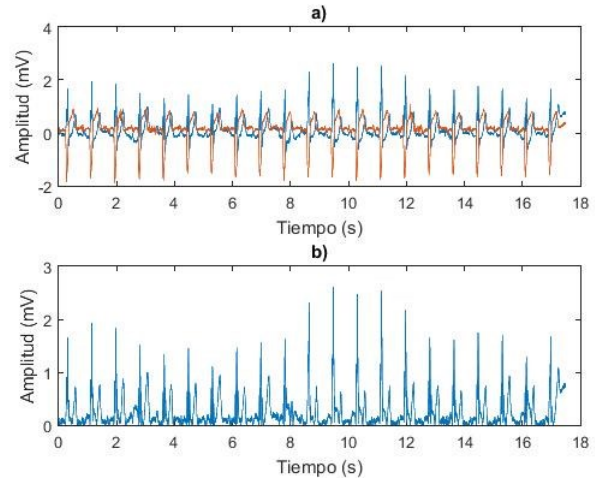


Fig. 2. (a) Señal de ECG de dos derivaciones diferentes, (b) Señal de ECG RMS a partir de las derivaciones anteriores.

B. Estimación de Coeficientes de Correlación Espectral de Señales Cicloestacionarias.

Las señales estacionarias, en sentido amplio, poseen características estadísticas (como valor medio, varianza y otras de orden superior) que no dependen del tiempo, mientras que las estacionarias en el sentido estricto, la función de densidad de probabilidades no es una función de tiempo. Un proceso aleatorio es cicloestacionario, en sentido estricto, si su función de distribución de probabilidades es periódica en el tiempo [36], [37] y además presentan la propiedad de correlación espectral. Correlación espectral significa que la señal original y su versión con desplazamiento de frecuencias están correlacionadas.

Desde el punto de vista matemático, se denomina señal cicloestacionaria a toda señal aleatoria que se le aplique cualquier transformación no lineal de orden superior y produzca una línea espectral en las frecuencias cíclicas diferentes de cero [31]. Una señal cicloestacionaria exhibe correlación espectral entre las componentes espectrales de la señal en la posición de las frecuencias cíclicas diferentes de cero [30].

Una señal $x(t)$ es cicloestacionaria con frecuencia cíclica a , demora τ y periodo T_0 , sí y solo sí, su producto conjugado demorado $y(t) = (x(t)x^*(t - \tau))$ produce una línea espectral en la frecuencia a .

En el caso del ruido, es de naturaleza aleatoria y el ruido aleatorio estacionario no tiene un pico en las frecuencias cíclicas diferentes de cero [30]. Esta propiedad permite separar las señales del ruido aditivo de fondo en las frecuencias cíclicas diferentes de cero.

Las propiedades generales de los procesos cicloestacionarios se derivan de la expansión en series de Fourier de la función de

autocorrelación, la cual es periódica. A los coeficientes de Fourier de la expansión de Fourier de la función de autocorrelación de una señal cicloestacionaria se les denomina función de autocorrelación cíclica CAF (Cyclic Autocorrelation Function). La transformada de Fourier de la CAF se denomina función de densidad de correlación espectral SCF (Spectral Correlation Density Function).

Si la función de autocorrelación $R_y(t, \tau)$ para una señal cicloestacionaria es periódica, entonces la descomposición en series de Fourier se puede realizar y resulta como:

$$R_y(t, \tau) = \sum_a R_y^a(\tau) e^{j2\pi a t} \quad (2)$$

Donde a es la frecuencia cíclica y se extiende sobre todos los múltiplos enteros de la frecuencia fundamental $1/T_0$. El coeficiente de Fourier $R_y^a(\tau)$ se denomina CAF y se define como indica en (3).

$$R_y^a(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} R_y(t, \tau) e^{-j2\pi a t} dt \quad (3)$$

Donde T es un intervalo de observación.

La función de autocorrelación $R_y(t, \tau)$ de (3) puede ser remplazada por el producto conjugado demorado simétrico y se expresa como:

$$R_y^a(\tau) = \lim_{T \rightarrow \infty} \int_{-T/2}^{T/2} x\left(t + \frac{\tau}{2}\right) x\left(t - \frac{\tau}{2}\right)^* e^{-j2\pi a t} dt \quad (4)$$

La función de correlación espectral (SCF) se define como la transformada de Fourier de la función de autocorrelación cíclica de $x(t)$. La SCF de la señal $x(t)$ viene dada por:

$$S_y^a(f) = \int_{-\infty}^{\infty} R_y^a(\tau) e^{-j2\pi f \tau} d\tau \quad (5)$$

La función SCF con componentes espectrales de $x(t)$ en las frecuencias $(f + a/2)$ y $(f - a/2)$ en el intervalo de observación de T es:

$$S_y^a(f) = \lim_{\Delta t \rightarrow \infty} \lim_{T \rightarrow \infty} \frac{1}{\Delta t} \frac{1}{T} \int_{-T/2}^{T/2} X_T\left(t, f + \frac{a}{2}\right) X_T^*\left(t, f - \frac{a}{2}\right) dt \quad (6)$$

De la ecuación (6), la componente espectral de $x(t)$ en la frecuencia f con periodo T es:

$$X_T(t, f) = \int_{-T/2}^{t+T/2} x(t) e^{-j2\pi f t} dt \quad (7)$$

La SCF es típicamente graficada en un plano bifrecuencial como una función de la frecuencia espectral f y la frecuencia cíclica a . El rango de valores de f (normalmente de $-f_s/2$ a $f_s/2$ donde f_s es la frecuencia de muestreo), y a (normalmente de $-f_s$ a f_s), para la cual existe $S_y^a(f)$ se conoce como la región de soporte en el plano bifrecuencial [38]. La SCF de diferentes tipos de señales crea patrones únicos que son dependientes de cada tipo. De este modo, la SCF se puede usar como un clasificador de señal basado en un esquema dado.

Los métodos de suavizado en el tiempo (Time smoothing) y suavizado en la frecuencia (Frequency smoothing) son las dos metodologías básicas principales para determinar la estimación espectral cíclica. El método de acumulación FFT, FAM (FFT

Accumulation method), es una implementación particular de la SCF. FAM se basa en un suavizado en el tiempo para obtener más eficientemente la función de correlación espectral [38], el cual se utiliza para obtener la estimación de la SCF de cada latido.

C. Extracción y Reducción del Espacio Características.

Gran parte de los coeficientes de correlación espectral representado como matrices son ceros. Antes de extraer características estadísticas para alimentar el clasificador, cada matriz se considera como una imagen y se utiliza el método de umbralización de Otsu [39] con el objetivo de obtener información sobre la ubicación de los objetos encontrados en cada imagen. Los objetos representan el contenido espectral principal y su ubicación se utiliza con el fin de recortar las imágenes en otras de menor tamaño que contenga esta información espectral.

La umbralización es una técnica de segmentación simple y eficiente que permite separar los píxeles de una imagen en escala de grises en dos categorías a partir de un valor umbral de intensidad [40]. El método de Otsu es uno de los más utilizados en la literatura. Considera que el histograma es bimodal y se itera a lo largo del histograma calculando para cada valor estimado posible de umbral la varianza de pesos dentro de cada clase o modo.

Luego de umbralizadas las imágenes correspondientes a las matrices, los límites de los objetos encontrados en cada una se promedian y se utilizan en forma de vértices delimitadores para recortar todas las matrices. Este paso del método evita añadir gastos de procesamiento computacionales innecesarios.

Para alimentar el clasificador se extraen características estadísticas de las matrices de correlación espectral recortadas. Se calcula el valor máximo, valor medio y varianza de los coeficientes de correlación espectral de los latidos en cada valor de frecuencia cíclica.

El término reducción de la dimensión es el proceso de representar una proyección de muestras a un espacio de poca dimensionalidad, proveniente de una alta dimensión de datos, el cual permite preservar la mayor información intrínseca de las muestras originales. Esta nueva proyección conviene en labores de aprendizaje supervisado. Con el nuevo espacio se espera una maximización de la precisión en la etapa de clasificación y una minimización del tiempo de ejecución del sistema de clasificación.

En este trabajo se utiliza PCA como método para reducir el espacio de características. Se caracteriza por proyectar una transformación lineal que expresa un nuevo sistema de vectores ortonormales, el cual describe el conjunto original de datos. Este proceso consta de maximizar la varianza para capturar el mayor número de muestras del conjunto de información y almacenarlos en nuevos ejes, donde el primer componente principal, es aquel eje de mayor varianza, el segundo componente principal posee la segunda varianza más grande, y así sucesivamente [41].

D. Red Neuronal Artificial

Las redes neuronales artificiales (ANN: Artificial Neural

Network) constituyen una herramienta útil en diversas áreas de la ciencia y la ingeniería. Son herramientas de inteligencia artificial que pueden aprender y generalizar a partir de ejemplos y experiencias para producir soluciones significativas a los problemas concretos [42]. Uno de los modelos más comunes y sencillos de utilizar es la ANN pre-alimentada (*feed-forward*) [43]. En esta metodología se utiliza las ANNs como herramienta de clasificación.

Para la implantación de la ANN se utilizó MATLAB™ Neural Network Toolbox, pues brinda las herramientas necesarias para crear y entrenar redes neuronales. Debido a que una ANN del tipo *feed-forward*, con una capa oculta y suficientes neuronas en la capa oculta, puede prácticamente adaptarse a cualquier problema de asignación de entrada/salida finita, se propone usarla en este trabajo.

La arquitectura propuesta está formada por una capa de entrada, una capa oculta y una capa de salida. La capa de entrada contiene tantas neuronas como categorías tiene el vector de características especificado en la sección anterior. Las neuronas de la capa de salida se corresponden con los cinco tipos de latidos de respuestas del sistema. En la Tabla I se muestra la topología de la ANN implementada y a continuación se explican algunos parámetros.

TABLA I
TOPOLOGÍA DE LA ANN IMPLEMENTADA

Parámetro	Valor
Función de activación	Tangente-Sigmoidea
Tasa de aprendizaje	1
Error permitido	1e ⁻⁶
Función de entrenamiento	Gradiente conjugado
Tiempo de convergencia	5 segundos
Neuronas de la capa oculta	10
Iteraciones	61

El tiempo de convergencia (5 segundos), es la duración que requirió la RNA tanto para la fase de entrenamiento como de prueba con el fin de establecer los pesos y *bias* que permitan realizar una clasificación acertada de la variación en el proceso. La función activación especificada es la de la capa oculta, en la capa de salida se utiliza función Sigmoidea-Logarítmica.

Para prevenir la aparición de los fenómenos de *Overfitting* (sobre-ajuste) y *Underfitting* (sub-ajuste), se definió una cantidad nominal de neuronas (30 neuronas) de la capa oculta a partir de criterios conocidos como *rules of thumb* [44] y del método de la pirámide geométrica. Luego se realizaron entrenamientos aumentando y disminuyendo el número de neuronas ocultas, con el fin de observar el impacto que tiene dicha variación en el rendimiento del algoritmo de la red neuronal durante el proceso de entrenamiento y validación.

Se ha realizado el proceso de entrenamiento incrementando el número de neuronas en la capa oculta de 5 en 5 hasta un máximo de 20 neuronas por encima de su valor nominal. La evaluación del desempeño se realiza mediante la obtención del área bajo la curva de las curvas ROC, las cuales arrojaron la arquitectura de 10 neuronas como la de mayor área, por lo que se implementa una red que posee 10 neuronas ocultas. Para el

entrenamiento de la red se usa el 70 % del conjunto de datos, mientras que para la validación y prueba se usa el 15 % de los datos para cada uno.

Para prevenir el sobre-ajuste de datos, también se aseguró que las clases estuvieran equilibradas y variadas en cantidad. En los tres experimentos la cantidad total de latidos fue 10000: 2000 latidos de cada clase. En el primer experimento de los 2000 latidos de cada clase, 1000 correspondían a cada uno de los canales de la base de datos. Se aseguró que los datos del conjunto de prueba no están contenidos en el conjunto de entrenamiento, lo cual permite obtener una valoración de aciertos/fallos real del modelo y detecta fácilmente efectos del sobre-ajuste /sub-ajuste.

E. MIT-BIH Arrhythmia Database

Para la validación se empleó la base de datos MIT-BIH Arrhythmia Database [45], MIT-BIH (*Massachusetts Institute of Technology- Beth Israel Hospital*). MIT-BIH Arrhythmia Database está entre las bases de datos más utilizadas para la validación de algoritmos para el análisis del ECG [46], [47].

Contiene 48 registros de media hora aproximadamente de ECG ambulatorios de dos canales pertenecientes a 47 personas estudiadas en el BIH. Los sujetos fueron 25 hombres de 32 a 89 años y 22 mujeres de 23 a 89 años. Los registros fueron digitalizados a 360 Hz por canal con una resolución de 11 bits en un rango de ± 5 mV. Dos o más cardiólogos anotaron independientemente cada registro y luego se resolvieron, conjuntamente y por consenso, las discrepancias existentes para obtener anotaciones de referencias legibles y fidedignas para cada latido.

F. Medidas de Evaluación

La evaluación del método propuesto de clasificación de arritmias se realiza mediante el cálculo de la sensibilidad, exactitud y especificidad del sistema de clasificación:

$$Sen = \frac{VP}{VP + FN} \times 100 \quad (8)$$

$$Esp = \frac{VN}{VN + FP} \times 100 \quad (9)$$

$$Ex = \frac{VP + VN}{Total_positivos + Total_negativos} \times 100 \quad (10)$$

Donde *VP* significa (Verdadero positivo), *FN* (Falso negativo), *VN* (Verdadero negativo) y *FP* (Falso positivo).

El vector de características que se declaró en la Sección D se conforma de 27879 latidos escogidos de la base de datos, de tal forma que estuvieran representados los cinco tipos de latidos: 13319, 3129, 2677, 4608 y 4146 para los tipos N, APC, VPC, LBBB y RBBB, respectivamente. Las pruebas de los casos de estudio se realizaron utilizando MATLAB (R2015a) en una PC con Intel Core i3 3,2 GHz y 4 GB de RAM.

III. RESULTADOS

Con el fin de conocer a priori el patrón de cada latido, en

las Fig. 3 y 4 se muestran los mapas de colores de las matrices de coeficientes de correlación espectral de los latidos señalados anteriormente. Note como $S_y^a(f)$ depende tanto de la frecuencia espectral f como de la frecuencia cíclica a . El contenido espectral se encuentra concentrado en una amplia zona de frecuencias espectrales y cíclicas. Los picos son más altos en la zona central. Se comprueba la hipótesis de que la señal de ECG posee periodicidad de segundo orden, demostrado en las componentes espectrales que presenta en las frecuencias cíclicas diferentes de cero.




Fig. 3. Mapas de color típicos de la función de correlación espectral de los tipos latidos de ECG: a) N, b) APC y c) VPC.




Fig. 4. Mapas de color típicos de la función de correlación espectral de los tipos latidos de ECG: a) LBBB y b) RBBB.

Las magnitudes de los coeficientes se corresponden con la escala de colores utilizada. El azul fuerte se degrada y pasa por amarillo hasta el rojo más intenso. En ese orden las mayores magnitudes se tiñen de rojo y las menores de azul intenso. Se puede comprobar que los latidos normales presentan las menores magnitudes de correlación espectral y estas cubren una amplia gama de frecuencias cíclicas a diferencia de cualquier tipo de arritmia. Le sigue en magnitud superior APC y luego RBBB, en las cuales las líneas espectrales también se extienden sobre un amplio rango de frecuencias cíclicas, pero se presentan menos densas y más claramente definidas en pequeños grupos y zonas.

Los de mayores magnitudes son LBBB y VPC, este último mayor que todos. Tienen además como distinción que las principales regiones de líneas espectrales, que igualmente

cubren una amplia gama de frecuencias cíclicas, son separadas entre sí. En las cinco imágenes todo la parte azul fuerte corresponde a valores iguales o aproximadamente iguales a cero como se explicó anteriormente.

Para conformar los vectores de clasificación a partir de las matrices de correlación espectral según la resolución de frecuencia f y frecuencia cíclica a usadas en [34] se obtienen matrices de coeficientes con dimensión d de 34833 coeficientes. En este trabajo se logra una dimensión de 17940 coeficientes lo que equivale a un menor costo computacional. La dimensión d viene dado por:

$$d = n_x * n_f \quad (11)$$

Donde n_x y n_f son el número de coeficientes en el dominio a y el dominio f , respectivamente.

Luego de reducir las matrices de coeficientes de correlación espectral mediante la eliminación de los elementos iguales o aproximadamente iguales a cero, se obtiene dimensión d de 9450, con valores de n_x y n_f igual a 1050 y 9, respectivamente. Luego se aplica PCA, logrando reducir más el espacio de características. El algoritmo de clasificación se prueba para distintos tamaños del espacio de características: 50, 100, 150 200 y 250. A medida que se reduce el espacio de características disminuyen los índices de desempeño de la red neuronal y a medida que aumenta la dimensión quedará mejor representado el espacio original. Existe un compromiso a la hora de elegir entre exactitud esperada de los parámetros evaluados y el costo computacional deseado. Se decide entrenar la red con un vector de 200 características.

De forma general el experimento realizado, alimentando el sistema con una señal multiderivación, muestra resultados satisfactorios por cuanto logra diferenciar los distintos tipos de latidos con altos porcentajes de los parámetros evaluados. En la Tabla II se muestran los valores de los parámetros evaluados en el sistema, obtenidos del promedio de cada uno de estos para todos los tipos de latidos.

TABLA II
RESULTADOS DE LA CLASIFICACIÓN UTILIZANDO SEÑAL DE ECG
MULTIDERIVACIÓN

Experimento	Sensibilidad (%)	Especificidad (%)	Exactitud (%)
Señal de ECG multiderivación	92.66	98.54	97.12

A pesar de que los resultados expuestos no son despreciables se quedan por debajo de los mostrados en [34] utilizando una metodología también basada en cicloestacionariedad. Logra sensibilidad, especificidad y exactitud de 99.2 %, 97.7 % y 98.6 %, respectivamente. En este trabajo se logran valores inferiores debido a que se evalúa para un conjunto de muestras formado con latidos de la derivación 1 y de la derivación 2. La metodología usada provoca mayor probabilidad de error y mayor dependencia de la derivación escogida del sistema dado por las distintas morfologías de cada tipo de latido, que se multiplican debido a la cantidad de derivaciones existentes. En contraposición, en

[34] se evalúa a partir de latidos de una sola derivación.

Para corroborar lo planteado se realiza el experimento anterior evaluándolo para una muestra de latidos provenientes solo de la primera derivación de la base de datos. En la Tabla III se muestran los resultados obtenidos para cada tipo de latido. Se comprueba que con el vector de características utilizado (8490 coeficientes más pequeño) se obtienen valores de sensibilidad y exactitud mayores, solo la especificidad ligeramente menor, en comparación con el experimento anterior mostrado en la Tabla II. En relación a la metodología expuesta por Aya F. Khalaf et al. en [34], las diferencias en los valores se deben a la significativa reducción del tamaño del vector de características.

TABLA III
RESULTADOS DE LA CLASIFICACIÓN UTILIZANDO SEÑAL DE ECG
UNIDERIVACIÓN

Tipo de latido	Sensibilidad (%)	Especificidad (%)	Exactitud (%)
APC	95.7	97.8	97.3
LBBB	97.6	97.7	97.7
Normal	97.6	97.9	97.8
RBBB	97.3	97.7	97.6
VPC	95.5	97.5	97.1
Total	96.7	97.7	97.5
Aya F. Khalaf	99.2	99.7	98.6

Con el segundo experimento, el método propuesto, que utiliza como señal de entrada la señal RMS logra resultados cualitativamente superiores. En la Tabla IV se muestra la comparación de los resultados arrojados en todos los experimentos. Como se puede observar los resultados son superiores cuando usamos el valor RMS de las derivaciones. Queda demostrado, en primer lugar, la robustez de este para combinar la información de un grupo de derivaciones en una nueva morfología como resultado de la integración RMS de las diferentes proyecciones eléctricas. Por otro lado, la superioridad de este experimento respecto al anterior se muestra por cuanto se obtienen mejores resultados de los parámetros evaluados.

TABLA IV
RESULTADOS DE LA CLASIFICACIÓN UTILIZANDO SEÑAL DE ECG RMS

Experimento	Sensibilidad (%)	Especificidad (%)	Exactitud (%)
Señal de ECG multiderivación	92.66	98.54	97.12
Aya F. Khalaf	99.20	99.70	98.60
Señal de ECG RMS	97.68	99.08	98.72

III. CONCLUSIONES

En este trabajo se propone un método de clasificación de arritmias basado en análisis de señales cicloestacionarias y en la integración del ECG en una señal RMS más robusta. El método propuesto clasifica 5 tipos de latidos cardíacos obteniendo índices generales de sensibilidad, especificidad y exactitud de 97,68 %, 99,08 % y 98,72 %, respectivamente. Además mediante la señal RMS se logra tener un enfoque global del fenómeno cardíaco debido a que tiene en cuenta

toda la información de las derivaciones contenidas en el registro de ECG.

Mediante la información de cicloestacionariedad se obtiene un modelo más realista de la señal debido a que esta no es estacionaria. Los coeficientes de correlación espectral obtenidos son usados como características para discriminar entre las distintas clases. Lo anterior permite excluir el efecto del ruido estacionario, que no posee naturaleza cíclica, lo que resulta en una ventaja al disminuir la complejidad del sistema.

Se logra la reducción del espacio de características mediante el uso de PCA con lo cual se disminuye el tiempo de procesamiento. Finalmente, el método multiderivación propuesto permite mantener el rendimiento del algoritmo independientemente de la derivación escogida, eliminando así la incertidumbre sobre cuál es la más adecuada para hacer la clasificación. Los trabajos futuros se enmarcan en perfilar la selección de características y reducción del espacio de estas, así como la evaluación de otras técnicas de machine learning.

REFERENCIAS

- [1] E. J. Benjamin, P. Muntner, and M. S. Bittencourt, "Heart disease and stroke statistics-2019 update: a report from the American Heart Association," *Circulation*, vol. 139, pp. e56-e528, 2019.
- [2] M. E. Herbert, S. R. Votey, M. T. Morgan, P. Cameron, and L. Dziukas, "Failure to agree on the electrocardiographic diagnosis of ventricular tachycardia," *Annals of Emergency Medicine*, vol. 27, pp. 35-38, 1996.
- [3] H. Gothwal, S. Kedawat, and R. Kumar, "Cardiac arrhythmias detection in an ECG beat signal using fast fourier transform and artificial neural network," *Journal of Biomedical Science and Engineering*, vol. 4, pp. 289, 2011.
- [4] Z. Zhang, J. Dong, X. Luo, K.-S. Choi, and X. Wu, "Heartbeat classification using disease-specific feature selection," *Computers in Biology and Medicine*, vol. 46, pp. 79-89, 2014.
- [5] S. Pal and M. Mitra, "Detection of Premature Ventricular Contraction Beats Using ANN," *International Journal of Recent Trends in Engineering and Technology*, vol. 3, 2010.
- [6] A. Garcia, H. Romano, E. Laciari, and R. Correa, "Development of an algorithm for heartbeats detection and classification in Holter records based on temporal and morphological features," in *Journal of Physics: Conference Series*, 2011, pp. 012-023.
- [7] M. Thomas, M. K. Das, and S. Ari, "Automatic ECG arrhythmia classification using dual tree complex wavelet based features," *AEU-International Journal of Electronics and Communications*, vol. 69, pp. 715-721, 2015.
- [8] G. Pan, Z. Xin, S. Shi, and D. Jin, "Arrhythmia classification based on wavelet transformation and random forests," *Multimedia Tools and Applications*, vol. 77, pp. 21905-21922, 2018.
- [9] J. A. Gutiérrez-Gnecchi, R. Morfin-Magana, D. Lorias-Espinoza, A. del Carmen Tellez-Anguiano, E. Reyes-Archundia, A. Méndez-Patiño, et al., "DSP-based arrhythmia classification using wavelet transform and probabilistic neural network," *Biomedical Signal Processing and Control*, vol. 32, pp. 44-56, 2017.
- [10] S. Sahoo, B. Kanungo, S. Behera, and S. Sabut, "Multiresolution wavelet transform based feature extraction and ECG classification to detect cardiac abnormalities," *Measurement*, vol. 108, pp. 55-66, 2017.
- [11] S. Banerjee and M. Mitra, "Application of cross wavelet transform for ECG pattern analysis and classification," *IEEE Transactions on Instrumentation and Measurement*, vol. 63, pp. 326-333, 2013.
- [12] R. J. Martis, U. R. Acharya, and L. C. Min, "ECG beat classification using PCA, LDA, ICA and discrete wavelet transform," *Biomedical Signal Processing and Control*, vol. 8, pp. 437-448, 2013.
- [13] R. J. Martis, U. R. Acharya, C. M. Lim, and J. S. Suri, "Characterization of ECG beats from cardiac arrhythmia using discrete cosine transform in PCA framework," *Knowledge-Based Systems*, vol. 45, pp. 76-82, 2013.
- [14] U. R. Acharya, H. Fujita, M. Adam, O. S. Lih, T. J. Hong, V. K. Sudarshan, et al., "Automated characterization of arrhythmias using nonlinear features from tachycardia ECG beats," in *2016 IEEE*

- International Conference on Systems, Man, and Cybernetics (SMC)*, 2016, pp. 000533-000538.
- [15] S. Hajeb-Mohammadipour, M. Ahmadi, R. Shahghadami, and K. Chon, "Automated Method for Discrimination of Arrhythmias Using Time, Frequency, and Nonlinear Features of Electrocardiogram Signals," *Sensors*, vol. 18, p. 2090, 2018.
- [16] F. A. Elhaj, N. Salim, A. R. Harris, T. T. Swee, and T. Ahmed, "Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals," *Computer Methods and Programs in Biomedicine*, vol. 127, pp. 52-63, 2016.
- [17] K. N. Rajesh and R. Dhuli, "Classification of ECG heartbeats using nonlinear decomposition methods and support vector machine," *Computers in Biology and Medicine*, vol. 87, pp. 271-284, 2017.
- [18] R. J. Martis, U. R. Acharya, H. Prasad, C. K. Chua, C. M. Lim, and J. S. Suri, "Application of higher order statistics for atrial arrhythmia classification," *Biomedical Signal Processing and Control*, vol. 8, pp. 888-900, 2013.
- [19] R. Nanjundegowda and V. Meshram, "Arrhythmia recognition and classification using kernel ICA and higher order spectra," *Int J Eng Technol*, vol. 7, pp. 256-262, 2018.
- [20] P. Rajpurkar, A. Y. Hannun, M. Haghpahani, C. Bourn, and A. Y. Ng, "Cardiologist-level arrhythmia detection with convolutional neural networks," *arXiv preprint arXiv:1707.01836*, 2017.
- [21] Ö. Yildirim, P. Plawiak, R.-S. Tan, and U. R. Acharya, "Arrhythmia detection using deep convolutional neural network with long duration ECG signals," *Computers in Biology and Medicine*, vol. 102, pp. 411-420, 2018.
- [22] S. M. Mathews, C. Kambhmettu, and K. E. Barner, "A novel application of deep learning for single-lead ECG classification," *Computers in Biology and Medicine*, vol. 99, pp. 53-62, 2018.
- [23] Y. Kutlu, G. Altan, and N. Allahverdi, "Arrhythmia classification using waveform ECG signals," in *International Conference on Advanced Technology & Sciences*, 2016.
- [24] G. Altan, Y. Kutlu, and N. Allahverdi, "A Multistage Deep Belief Networks Application on Arrhythmia Classification," *International Journal of Intelligent Systems and Applications in Engineering*, pp. 222-228, 2016.
- [25] U. R. Acharya, H. Fujita, O. S. Lih, Y. Hagiwara, J. H. Tan, and M. Adam, "Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network," *Information Sciences*, vol. 405, pp. 81-90, 2017.
- [26] G. M. Friesen, T. C. Jannett, M. A. Jadallah, S. L. Yates, S. R. Quint, and H. T. Nagle, "A comparison of the noise sensitivity of nine QRS detection algorithms," *IEEE Transactions on Biomedical Engineering*, vol. 37, pp. 85-98, 1990.
- [27] C. Fisch, "Centennial of the string galvanometer and the electrocardiogram," *Journal of the American College of Cardiology*, vol. 36, pp. 1737-1745, 2000.
- [28] C. Van Mieghem, M. Sabbe, and D. Knockaert, "The clinical value of the ECG in noncardiac conditions," *Chest*, vol. 125, pp. 1561-1576, 2004.
- [29] M. L. Soria, J. P. Martinez, and P. Laguna, "A multilead wavelet-based ECG delineator based on the RMS signal," in *2006 Computers in Cardiology*, 2006, pp. 153-156.
- [30] W. A. Gardner, "Cyclostationarity in communications and signal processing," *Statistical Signal Processing Inc Yountville Ca1994*.
- [31] W. A. Gardner, A. Napolitano, and L. Paura, "Cyclostationarity: Half a century of research," *Signal processing*, vol. 86, pp. 639-697, 2006.
- [32] A. Napolitano, "Cyclostationarity: New trends and applications," *Signal Processing*, vol. 120, pp. 385-408, 2016.
- [33] G. B. Giannakis, "Cyclostationary signal analysis," *Digital Signal Processing Handbook*, pp. 17.1-17.31, 1998.
- [34] A. F. Khalaf, M. I. Owis, and I. A. Yassine, "A novel technique for cardiac arrhythmia classification using spectral correlation and support vector machines," *Expert Systems with Applications*, vol. 42, pp. 8361-8368, 2015.
- [35] A. V. Dandawate and G. B. Giannakis, "Nonparametric polyspectral estimators for kth-order (almost) cyclostationary processes," *IEEE transactions on Information Theory*, vol. 40, pp. 67-84, 1994.
- [36] W. A. Gardner, *Introduction to Random Processes: With Applications to Signals and Systems* vol. 31.
- [37] A. Papoulis, "Random Variables and Stochastic Processes," *McGraw Hill*, 1976.
- [38] C. Tom, "Cyclostationary spectral analysis of typical satcom signals using the fft accumulation method," *Defence Research Establishment Ottawa (Ontario)1995*.
- [39] N. Otsu, "A threshold selection method from gray-level histograms," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 9, pp. 62-66, 1979.
- [40] N. Triana, A. E. Jaramillo, R. M. Gutiérrez, and C. A. Rodríguez, "Técnicas de umbralización para el procesamiento digital de imágenes de GEM-Foils," *Scientia et Technica*, vol. 21, pp. 352-359, 2016.
- [41] F. Husson, S. Lê, and J. Pagès, *Exploratory Multivariate Analysis by Example Using R*: chapman and hall/CRC, 2017.
- [42] M. Rafiq, G. Bugmann, and D. Easterbrook, "Neural network design for engineering applications," *Computers & Structures*, vol. 79, pp. 1541-1552, 2001.
- [43] A. A. Lopez-Hernandez, R. F. Martinez-Gonzalez, J. A. Hernandez-Reyes, L. Palacios-Luengas, and R. Vazquez-Medina, "A Steganography Method Using Neural Networks," *IEEE Latin America Transactions*, vol. 18, pp. 495-506, 2020.
- [44] J. Mohammed, S. Bahadoorsingh, N. Ramsamooj, and C. Sharma, "Performance of exponential smoothing, a neural network and a hybrid algorithm to the short term load forecasting of batch and continuous loads," in *2017 IEEE Manchester PowerTech*, 2017, pp. 1-6.
- [45] G. B. Moody and R. G. Mark, "The impact of the MIT-BIH arrhythmia database," *IEEE Engineering in Medicine and Biology Magazine*, vol. 20, pp. 45-50, 2001.
- [46] J. P. Martinez, R. Almeida, S. Olmos, A. P. Rocha, and P. Laguna, "A wavelet-based ECG delineator: evaluation on standard databases," *IEEE Transactions on Biomedical Engineering*, vol. 51, pp. 570-581, 2004.
- [47] E. A. Junior, R. A. de Medeiros Valentim, and G. B. Brandao, "Real time QRS detection based on redundant discrete wavelet transform," *IEEE Latin America Transactions*, vol. 14, pp. 1662-1668, 2016.



Neurys Gómez recibe el título de Ingeniero en Telecomunicaciones y Electrónica en la Universidad de Oriente, Santiago de Cuba, en el año 2013. En el año 2018 recibe el título de Máster en Sistemas de Telecomunicaciones en la misma universidad. Actualmente es estudiante del Doctorado en Ingeniería

Biomédica de la Universidad de Oriente y sus investigaciones se dirigen al campo de procesamiento de señales biomédicas, particularmente señales de ECG. Es profesor asistente del departamento de Telecomunicaciones de dicha universidad.



Maikel Noriega recibe el título de Ingeniero en Telecomunicaciones y Electrónica en la Universidad de Oriente, Santiago de Cuba, en el año 2004. En el año 2010 recibe el título de Máster en Ingeniería Biomédica en la Universidad de Zaragoza, España. El título de Dr. CT. lo recibe en la Universidad de Oriente, en el año 2017 con

investigaciones en el campo del procesamiento de señales biomédicas. Actualmente es Profesor Titular. Sus intereses de investigación incluyen el procesamiento de señales, particularmente señales de ECG.