

Detección de Arritmias en Señales de ECG Basado en Máquinas de Vectores de Soporte

David Matheus*, Sergio Villazana, Cesar Seijas

Centro de Investigación en Bioingeniería, Centro de Investigación y Tecnología en Automatización, Electrónica y Control, Universidad de Carabobo. Facultad de Ingeniería, Esc. de Ing. Eléctrica, Av. Universidad, Bárbula, Naguanagua-Venezuela.

Resumen.-

Este trabajo presenta una metodología basada en máquinas de vectores de soporte para detectar anomalías en señales de ECG en un espacio complejidad de Lempel-Ziv y entropía de Shannon. Una señal de ECG con 26 arritmias (3 tipos de arritmias diferentes, contracción prematura ventricular, latido prematuro nodal y fusión de latido ventricular y normal) fue seleccionada de la base de datos MIT-BIH Arrhythmia Database, y fue pre-procesada para remover ruido debido al movimiento muscular y la respiración, artefactos por movimientos de los electrodos, interferencia de la línea de 60 Hz y componentes DC. La señal de ECG se dividió en 416 segmentos (cada segmento es un ciclo de ECG completo) de longitud variable que considera la variabilidad del ritmo cardiaco. El conjunto de datos de entrada para el entrenamiento de la máquina de una sola clase basada en SVM (SVM-1-clase) se obtuvo al aplicar el algoritmo de complejidad de Lempel-Ziv y el cálculo de la entropía de Shannon a los primeros 77 segmentos diagnosticados normales de la señal de ECG, de los cuales se tomó al azar el 80 % para entrenamiento y el resto para validación. La SVM-1-clase fue capaz de detectar los tres (3) tipos de arritmias mencionadas anteriormente. La precisión en la detección fue del 96.15 % (detectó 25 de las 26 arritmias presentes en la señal de ECG).

Palabras clave: Detección de anomalías, SVM, ECG, Complejidad Lempel-Ziv, Entropía de Shannon.

Support Vector Machines Based Arrhythmia Detection from ECG Signal

Abstract.-

This paper presents a methodology based on support vector machines to detect anomalies in ECG signals in a Lempel-Ziv complexity and Shannon entropy space. An ECG signal with 26 arrhythmias (three different types of arrhythmias, premature ventricular contractions, nodal premature beat and fusion of ventricular and normal beat) was selected from the Arrhythmia MIT-BIH Database, and was pre-processed to remove noise due to muscle movement and breathing motion artifacts of the electrodes, interference from power line and DC components. The ECG signal was divided into 416 segments (each segment is a complete ECG cycle) of variable length that considers the variability of heart rate. The input data set for training the one-class SVM (one class-Support Vector Machines) was obtained by applying the algorithm of Lempel-Ziv complexity and calculation of Shannon entropy to the first 77 segments diagnosed as normal segments, of which 80 % was taken for training and the rest for validation. The one-class SVM was able to detect three (3) kinds of arrhythmia which were mentioned before. Detection accuracy was 96.15 % (it detected 25 of the 26 arrhythmias present in the ECG signal).

Keywords: Anomaly detection, SVM, ECG, Lempel-Ziv complexity, Shannon entropy.

*Autor para correspondencia

Correos-e: dmatheus@uc.edu.ve (David Matheus),

svillaza@uc.edu.ve (Sergio Villazana),

cseijas@uc.edu.ve (Cesar Seijas)

Recibido: 11 agosto 2010

Aceptado: 3 diciembre 2010

1. INTRODUCCIÓN

La electrocardiografía es un procedimiento no invasivo que registra electrónicamente los cambios eléctricos de la actividad del corazón. El registro de la actividad eléctrica del corazón se conoce como electrocardiograma (ECG). El análisis del ECG permite hacer detección y diagnóstico de anormalidades severas del corazón. Los ritmos cardiacos anormales del corazón se conocen como arritmias, las cuales son frecuentemente detectables en un electrocardiograma. Las arritmias revelan frecuentemente cambios estocásticos [1], y pueden variar entre personas y dependen también de otros factores como edad y sexo del paciente. Hay muchos trabajos para la detección de arritmias [2], por medio del uso análisis de componentes principales [2-3], modelos de Markov ocultos [4], análisis de grupos [5], análisis energía-frecuencia [2], [6].

Kolmogorov [7] definió la complejidad de una cadena de una secuencia (de números, letras, etc) como el número de bits necesarios para hacer el programa de computadora más corto el cual es capaz de generar la cadena de la secuencia. En general, la complejidad mide el grado de aleatoriedad de una secuencia. Medidas usuales de la complejidad son el análisis de patrones simbólicos y la entropía. La complejidad Lempel-Ziv (CLZ) es un ejemplo del análisis de patrones simbólicos. La CLZ de una secuencia, la cual fue definida por Lempel y Ziv [8], mide el número de patrones diferentes de una secuencia. La entropía de una variable aleatoria se define en términos de su distribución de probabilidad y se puede demostrar que es una buena medida de su aleatoriedad o incertidumbre, es decir, la entropía de la incertidumbre u orden en una señal. Baja entropía (cercana a cero) significa orden o baja complejidad, y alta entropía (cercana a uno) significa bajo orden o alta complejidad. Shannon [9] dio algunas respuestas a la pregunta de cómo medir la cantidad de incertidumbre en la teoría de probabilidad clásica. Él estableció la entropía de

Shannon como una forma de medir la cantidad de incertidumbre por una función de distribución de probabilidad sobre un conjunto finito [10].

La detección de anomalías se refiere al problema de encontrar patrones en los datos que no se ajustan al comportamiento estadístico esperado. Estos patrones no conformes tienen distintas denominaciones, que dependen del dominio de aplicación, como novedades, anomalías, valores con desviaciones extremas (outliers), observaciones discordantes, excepciones, aberraciones, sorpresas. De éstas, las anomalías y los valores con desviaciones extremas son dos términos que se utilizan con más frecuencia en el campo de la detección de anomalías [11].

Las principales aplicaciones de la detección de anomalías son la detección de fraudes de tarjetas de crédito, de seguros o de atención de la salud, detección de intrusos en sistemas informáticos (ciber-seguridad), detección de fallas en sistemas críticos de seguridad y vigilancia militar de actividades enemigas. Las Máquinas de Vectores de Soporte (Support Vector Machine, SVM, p sus siglas en inglés) son una rama de la inteligencia artificial cuyas aplicaciones en áreas multidisciplinarias de ingeniería son relativamente nuevas.

En general, las SVM proyectan los vectores de entrada (datos de entrada) en un espacio de rasgos hiperdimensional a través de una proyección no lineal para hallar a un hiperplano separador óptimo que mejor modele a los datos de entrada. Las SVM han sido implementadas en problemas de regresión, clasificación y agrupamiento.

El clasificador de una sola clase basado en las máquinas de vectores de soporte es un algoritmo de aprendizaje no supervisado que separa a los puntos de datos de entrenamiento del origen del espacio de rasgos por medio de un hiperplano óptimo separador (HSO). Para este algoritmo solo existen datos de una sola clase (clase +1), y en este sentido se considera al algoritmo no supervisado. Cuando la máquina es entrenada, cualquier dato de prueba que esté del lado del HSO opuesto al origen del espacio de rasgos se considera de clase +1. En el caso de cualquier punto de prueba que este del lado del HSO donde se encuentre el

origen es considerado -1. Es importante señalar que los datos que sean considerados clase -1 no necesariamente son de la misma naturaleza, solo indica que su comportamiento es distinto a aquellos datos que fueron etiquetados como normales (clase +1).

Este estudio propone un proceso para la detección de arritmias presentes en señales ECG usando como herramienta de inteligencia artificial el clasificador de una sola clase. Las entradas a la máquina de una sola clase corresponden a la complejidad LZ y la entropía de Shannon de los segmentos de la señal ECG, las cuales fueron seleccionadas debido a que ellas son una medida del orden (entropía) y de los cambios de patrones (CLZ) de dicha señal. Es importante resaltar que el algoritmo de detección de arritmias no está basado en el estudio morfológico (en el tiempo) de los ciclos de ECG sino en el análisis de la señal en un espacio de rasgos estadístico (CLZ y la entropía de Shannon). La máquina de una sola clase tuvo una alta tasa de detección de arritmias en la señal de ECG envuelta en esta investigación.

2. REVISIÓN TEÓRICA

2.1. Arritmias

Las arritmias son alteraciones del ritmo cardíaco -aumento, disminución o falta de regularidad de la frecuencia cardíaca- que ocurren como resultado de un mal funcionamiento del sistema eléctrico del corazón. Estas anomalías también se presentan como alteraciones morfológicas de las señales ECG. Las arritmias se pueden clasificar en [2,12]: a) Arritmias sinusales; b) Arritmias supraventriculares; c) Ritmos de unión aurículoventricular (AV); d) Contracciones prematuras o latidos cardíacos ectópicos ; e) Arritmias ventriculares sostenidas; f) Bloqueo aurículoventricular.

2.2. Detección de Anomalías

Las anomalías son patrones en los datos que no se ajustan o se desvían de un comportamiento bien definido y considerado como normal. La Figura 1 muestra un segmento de señal ECG que presenta una anomalía (contracción prematura ventricular) entre los 85 y 87 milisegundos.




Figura 1: Ejemplo de una señal ECG con anomalía (arritmia).

Las anomalías pueden ser inducidas en los datos por una variedad de razones que dependen de la naturaleza de la señal y del sistema donde esté envuelta dicha señal. Para el caso de señales electrocardiográficas, estas anomalías pueden ser inducidas por problemas fisiológicos del corazón. Un método directo para la detección de anomalías, es definir una región que representa el comportamiento normal y declarar toda observación en los datos que no pertenecen a esta región normal como una anomalía [11], para ello se necesita, en muchos casos, la opinión de los especialistas en cardiología. En el análisis de detección de anomalías los datos, por lo general, un conjunto de muestras -referidas usualmente como ejemplos, puntos, vectores, patrones, observaciones, etc.- pueden tener uno o más atributos diferentes; en el caso que trata esta investigación los atributos son la complejidad Lempel-Ziv y la entropía de Shannon de la señal.

2.3. Clasificador de una Sola Clase

El objetivo principal de esta máquina de aprendizaje es hallar al hiperplano más alejado del origen, en el espacio de rasgos (ver Fig. 2), que separa a todos los datos hacia al lado (del hiperplano) opuesto al origen [12], [13]. Esto se logra al minimizar

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

sujeto a las restricciones $w^T \Phi(X_I) \geq \rho - \xi_i$, $\xi_i \geq 0$, $\rho \geq 0$, donde w es la normal del hiperplano, ρ es la distancia del hiperplano al origen, y v controla la influencia de los datos atípicos (outliers) al




Figura 2: Representación bidimensional de los puntos de datos en el espacio de rasgos.

ponderar el peso de estos datos (ξ_i) sobre la solución óptima.

La función Lagrangiano de (1) es

$$L = \frac{1}{2} w^T w + \frac{1}{vn} \sum_{i=1}^n \xi_i - \rho - \sum_{i=1}^n \alpha_i (w^T \Phi(x_i) + \xi_i - \rho) - \sum \beta_i \xi_i, \text{ sujeta a } \alpha_i, \xi_i \geq 0 \quad (2)$$

Tomando las derivadas parciales de la ecuación (2) con respecto a w , ξ_i , ρ e igualando a cero conduce a

$$dL/dW = 0 \rightarrow w = \sum \alpha_i \Phi(x_i) \quad (3)$$

$$dL/d\xi_i = 0 \rightarrow \alpha_i + \beta_i = 1/vn \quad (4)$$

$$dL/d\rho = 0 \rightarrow \sum \alpha_i = 1 \quad (5)$$

Sustituyendo las ecuaciones (3) a la (5) en la ecuación (1) y tomando en cuenta $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ conduce a la forma dual de la ecuación (1)

$$\begin{aligned} \min \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j \Phi^T(x_i) \cdot \Phi(x_j) \\ = \min \frac{1}{2} \sum_i \alpha_i \alpha_j K(x_i, x_j) \end{aligned} \quad (6)$$

$K(x_i, x_j)$ es la matriz kernel, para este estudio se utilizará la función kernel Gaussiana

$K(x_i, x_j) = e^{-\|x_i - x_j\|^2 / 2\sigma^2}$ donde el parámetro σ es el ancho de la Gaussiana.

Las condiciones KKT [14] establecen que

$$\alpha(w^T \Phi(x_i) + \xi_i - \rho) = 0 \quad (7)$$

$$\beta_i \xi_i = (1/vn - \alpha_i) \xi_i = 0 \quad (8)$$

La Tabla 1 resume las diferentes condiciones que definen cuando un punto de los datos es un VS y cuando no es un VS, considerando las ecuaciones (7) y (8).

2.4. Complejidad Lempel-Ziv.

CLZ es una medida del número de patrones diferentes de una secuencia finita. Antes de determinar la complejidad de una señal hay que transformarla en una secuencia compuesta de unos pocos símbolos [8], [15]. Una señal biomédica discreta se convierte en una secuencia binaria según un criterio predefinido, al compararla con un umbral (Td) [16]. Dada una señal discreta $X = x(1), x(2), \dots, x(n)$, esta se convierte en una secuencia finita $S = s(1), s(2), \dots, s(n)$ de unos y ceros como sigue

$$s(i) = \begin{cases} 0, & \text{if } x(i) < Td \\ 1, & \text{if } x(i) \geq Td \end{cases}, i = 1, 2, \dots, n$$

Para calcular la complejidad LZ de una secuencia, esta es explorada de izquierda a derecha y un contador de complejidad $c(n)$ se incrementa en una unidad cuando se halla a un nuevo patrón de caracteres consecutivos [15]. Por ejemplo, la complejidad Lempel-Ziv de $s=001111000011100001111001100011110$ es 7, debido a que los patrones observados en s son $|001|1110|0001|1100001111|00110|0011110$.

Una cota superior de $c(n)$ es $b(n) = n/\log_m(n)$ [16], [17], donde m es el número de símbolos diferentes. La CLZ normalizada $C(n)$ de una secuencia aleatoria arbitraria de longitud n es $C(n) = c(n)/b(n)$ [16], [17].

Tabla 1: Resumen de condiciones que definen a un vector de soporte y otros puntos

Vector de Soporte	Condiciones	Distancia
BSV	$\alpha_i = 1/vn, \xi_i > 0$	$w^T \Phi(x) <$
Vectores de Soporte	$0 < \alpha_i < 1/vn, \xi_i = 0$	$w^T \Phi(x) =$
No-Vectores de Soporte	$\alpha_i = 0, \xi = 0$	$x^T \Phi(x) > \rho$

2.5. Entropía de Shannon (ES).

La entropía es una medida que cuantifica el nivel de aleatoriedad o incertidumbre de una señal. Como una idea intuitiva, la entropía de un sistema es proporcional al logaritmo del número de sus posibles estados. Shannon estableció la ES como la forma de medir el grado de incertidumbre por una función de distribución de probabilidad sobre un conjunto finito [10]. La entropía de Shannon de una señal muestreada $X = x_1, x_2, \dots, x_n$ se escribe $H(X)$ y está definida como sigue:

$$H(X) = - \sum_{i=1}^n p(x_i) \log p(x_i) \quad (9)$$

donde $p(x_i)$ es la función de distribución de probabilidad (asigna a x_i una probabilidad entre 0 y 1).

3. PARTE EXPERIMENTAL

3.1. Preprocesamiento de Señales ECG.

La señal ECG para el análisis se obtuvo de la MIT-BIH Arrhythmia Database [18]. Cada señal de la MIT-BIH Arrhythmia Database fue muestreada a una frecuencia de 360 Hz. El registro 114 se tomó como señal para realizar el presente estudio, dicha señal tiene una longitud de 648.000 muestras (30 minutos). Para este estudio se tomaron las primeras 162.500 muestras (7,52 minutos) que corresponden a 416 ciclos de ECG, de los cuales 390 son ciclos normales y 26 son ciclos ECG con arritmias.

En la Figura 3 se muestran los primeros sesenta segundos (correspondiente a los primeros 77 ciclos ECG) del registro 114 [18], allí se observa la anotación por puntos (y la letra N mayúscula) que indica que los ciclos corresponden a patrones normales; dicha anotación fue establecida por los expertos del MIT-BIH Arrhythmia Database.



Figura 3: Primer segmento de 1 minuto del registro 114 del MIT-BIH Arrhythmia Database utilizado para generar el conjunto de entrenamiento..

De los 26 segmentos (un ciclo ECG) con arritmias 24 de ellas corresponden a contracción prematura ventricular (CPV), una es latido prematuro nodal (LPN) y la última es una fusión de latido ventricular y normal (FLVN), ver Figuras 5, 6 y 7.

La señal ECG fue preprocesada para remover el ruido debido al movimiento muscular y de respiración, artefactos por el movimiento de los electrodos, interferencias de la línea de 60 Hz y componentes DC. La señal de ECG fue dividida en 416 segmentos (cada segmento es un ciclo de ECG completo) de longitud variable que considera la variabilidad del ritmo cardiaco, a los cuales se le calcularon la complejidad de Lempel-Ziv y la entropía de Shannon.

El conjunto de datos de entrada para el entrenamiento de la máquina de una sola clase basada en SVM (SVM-1-clase) fue obtenido al seleccionar los primeros 77 puntos (correspondientes a los primeros 77 segmentos diagnosticados normales de la señal de ECG, ver Fig. 3), de los cuales se tomó al azar el 80 % para entrenamiento y el resto para validación.

La Fig. 4a muestra la distribución de los 416 puntos correspondiente a cada segmento ECG. La Fig. 4b muestra a los 77 puntos de entrenamiento (61 puntos) validación (16 puntos) en el espacio ES-CLZ. Los puntos identificados con equis son




Figura 4: a) Distribución de los segmentos ECG en el espacio ES-LZIV, b) Conjunto de datos de entrenamiento en el espacio ES-LZIV.

los datos para entrenar a la máquina de una sola clase y los puntos identificados con asterisco son los datos para validación.

El conjunto de pruebas corresponde al universo de los puntos en el espacio ES-CLZ (Fig. 2), es decir, los 77 datos correspondiente al conjunto de entrenamiento y los 339 restantes que no fueron utilizados en la etapa de entrenamiento y validación.

3.2. Entrenamiento del Clasificador de una sola clase.

La librería usada para entrenar al clasificador de una sola clase fue LIBSVM [19]. La Tabla 2 muestra los mejores parámetros obtenidos durante el proceso de entrenamiento del clasificador. Como se muestra en dicha tabla, el número de grupos se puede ajustar variando los parámetros ν y σ de la SVM.

En la Tabla 2 se observa que la predicción del clasificador de una sola clase utilizando como datos de entrada los mismos datos de entrenamiento fue del 100 %, también se muestra en dicha tabla que la predicción sobre los datos de validación (datos que no fueron utilizados durante el entrenamiento del clasificador) fue también del 100 %, como debería esperarse en un buen diseño, ya que todos estos datos corresponden a segmentos ECG normales.

Como se mencionó anteriormente, los datos de prueba corresponden a los 416 puntos que representan los 7,52 minutos del registro 114, no obstante, solo se mostrarán gráficamente los resultados más relevantes. El desempeño general del clasificador de una sola clase sobre los 416 segmentos totales se muestra en la Tabla 3.

En la Tabla 3, la columna “Predicción Global” indica el número de aciertos correspondientes a los segmentos normales y con arritmias identificados correctamente, la columna correspondiente a “Positivos Verdaderos” corresponde al éxito en la predicción del detector de anomalías de los segmentos correspondiente solo a la clase normal, la columna correspondiente a “Negativos Verdaderos” corresponde al éxito en la predicción del detector de anomalías de los segmentos correspondiente solo aquellos con arritmias, la columna “Falsos Positivos” indica que el detector falló en detectar a un segmento con arritmia (correspondiente a la arritmia CPV) solamente y, la última columna “Falsos Negativos” corresponde a ciclos normales identificados como arritmias.

En la primera sección de sesenta segundos del registro, el detector de anomalías identificó a todos los segmentos como normales (como efectivamente lo son, ver Fig. 3). En la sección desde el minuto dos hasta el minuto cuatro el detector de anomalías identificó a las cuatro arritmias CPV presentes (hubo cinco falsos positivos en esta sección).




Figura 5: Quinto segmento de 1 minuto del registro 114. Gráfica Superior: Segmentos a trazo fuerte identificados como arritmias. Gráfica Inferior: Anotación de la base de datos.

En la parte superior de la Figura 5 (minuto cuatro al minuto cinco) se resaltan en trazo mas fuerte los segmentos identificados por el detector de anomalías como arritmias, la letra “A” sobre un segmento indica la presencia de la arritmia sobre el mismo, como se muestra en la parte inferior de la Fig. 5 que muestra la anotación sobre el registro 114 según la base de datos [18].

En este caso la letra “A” indica la presencia

Tabla 2: Resumen de la entonación de parámetros del clasificador de una sola clase

Parámetros de la SVM		#VS	Predicción de los datos:	
Nu (ν) 0.01	Sigma (σ) 0.80		Entrenamiento	Validación
		2	100 %	100 %

Tabla 3: Resumen del desempeño del detector de anomalías

Predicción Global	Positivos Verdaderos	Negativos Verdaderos	Falsos Positivos	Falsos Negativos
93,75 % (390 de 416)	93,59 % (365 de 390)	96,15 % (25 de 26)	3,85 % (1 ciclo)	6,41 % (25 ciclos)

de cualquiera de los tres tipos de arritmias que presenta el registro 114. Se puede observar en la parte superior de la Figura 5, que el detector de anomalías detectó nueve de las diez arritmias presentes en esa sección, solo fallando en detectar la arritmia CPV que ocurrió aproximadamente a los 258 segundos. En esta sección hubo seis falsos negativos.




Figura 6: Sexto segmento de 1 minuto del registro 114. Gráfica Superior: Segmentos a trazo fuerte identificados como arritmias. Gráfica Inferior: Anotación de la base de datos.




Figura 7: Séptimo segmento de 1 minuto del registro 114. Gráfica Superior: Segmentos a trazo fuerte identificados como arritmias. Gráfica Inferior: Anotación de la base de datos.

Las Fig. 6 y 7 muestran a la sexta y séptima sección respectivamente del registro 114 y se evidencia el éxito en la detección de las arritmias que tuvo el detector de anomalías. En la Fig. 6 se observa que el detector de anomalías detectó dos de las arritmias que están muy cercanas entre si (aproximadamente segundo 339). En la Fig. 5 y en la Fig. 7 se observa que el detector de anomalías detectó los dos segmentos con arritmias LPN (aproximadamente segundo 240 en la Fig. 5, identificado con la letra "J") y FLVN (aproximadamente segundo 369 en la Fig. 7, identificado con la letra "F").

4. CONCLUSIONES

Los resultados demostraron que el detector de anomalía implementado con el clasificador de una sola clase tuvo un excelente desempeño en la detección de arritmias en una señal ECG. De las 26 arritmias presentes en el segmento de 7,52 minutos del registro 114 analizado, el detector de anomalías identificó a 25 ciclos de ECG anómalos, fallando solamente en la detección de una arritmia correspondiente al latido de contracción prematura ventricular (CPV), representando un porcentaje de detección del 96,15 % sobre los segmentos anómalos. De acuerdo a los ensayos realizados, se verifica que la precisión de la detección de las arritmias depende de la variabilidad del ritmo cardíaco (VRC), por tanto, hay que considerar la VRC durante el proceso de extracción de los segmentos de un (1) ciclo de ECG. Es importante resaltar que si bien el detector de anomalías dio

25 falsos positivos, esto no representa riesgo, ya que esta máquina de inteligencia artificial es una herramienta de ayuda para el análisis rápido del registro ECG del paciente por parte del médico especialista en cardiología, el cual está en capacidad de verificar la exactitud del análisis hecho por el detector de anomalías.

Referencias

- [1] Lerma, C., Krogh-Madsen T., Guevara, M. y Glass, L. 'Stochastic Aspects of Cardiac Arrhythmias', en *Journal of Statistical Physics*, Springer US, 26.08.2006, vol. 128, no. 1, pp. 347-374.
- [2] Clifford, G., D., Azuaje, F., y McSharry, P. E., Eds., *Advanced Methods and Tools for ECG Data Analysis*, Norwood, Artech House, Inc., 2006.
- [3] Mark, R. G., y Moody, G. B., 'ECG Arrhythmia Analysis: Design and Evaluation Strategies' Chapter 18, in I. Gath and G. F. Inbar, (eds.), *Advances in Processing and Pattern Analysis of Biological Signals*, New York: Plenum Press, pp. 251-272, 1996.
- [4] Coast DA, Stren RM, Cano GG, Briller SA, 'An Approach to Cardiac Arrhythmia Analysis Using Hidden Markov Models', *IEEE Trans. Biomed. Eng.*, No. 37, pp. 826-836, 1990.
- [5] Zhou, S. H., Rautaharju, P. M., y Calhoun, H. P., 'Selection of a Reduced Set of Parameters for Classification of Ventricular Conduction Defects by Cluster Analysis', *Computers in Cardiology*, Vol. 20, pp. 879-882, 1993.
- [6] Barro, S, Ruiz, R, Cabello, D, y Mira J., 'Algorithmic Sequential Decision-Making in the Frequency Domain for Life Threatening Ventricular Arrhythmias and Imitative Artifacts: A Diagnostic System', *J. Biomed. Eng.*, No. 11, pp. 320-328, 1989.
- [7] Kolmogorov, A. N., 'Three approaches to the quantitative definition of information', en *Problems of Information Transmission*, Vol. 1, pp. 1-7, 1965.
- [8] Lempel, A., Ziv, J., On the complexity of finite sequences. *IEEE Transactions on Information Theory*, IT-22, pp. 75-81, 1976.
- [9] Shannon, C. E., 'The mathematical theory of communication' en *The Bell System Technical Journal*, 27(3&4), pp. 379-423, 623-656, 1948.
- [10] Klir, G., Eds., *Uncertainty and Information Foundations of Generalized Information Theory*, Hoboken, New Jersey, John Wiley & Sons, Inc, 2006.
- [11] V Chandola, A Banerjee, V Kumar, 'Anomaly detection: A survey', en *ACM Computing Surveys (CSUR)*, Vol. 41, Nro 3, pp. 1-58, Julio 2009.
- [12] Paul A. Iaizzo, Eds., *Handbook of Cardiac Anatomy, Physiology, and Devices*, Totowa, New Jerse, Humana Press Inc., 2005.
- [13] Schölkopf, B., Platt, J.C., Shawe-Taylor, J., Smola, A.J., y Williamson, R.C., "Estimating the support of a highdimensional distribution," Microsoft Research Corporation Technical Report MSR-TR-99-87, 1999.
- [14] B. Schölkopf, R.C. Williamson, A.J. Smola, J. Shawe-Taylor, and J. Platt., Support vector method for novelty detection, in *Advances in Neural Information Processing Systems 12: Proceedings of the 1999 Conference*, Sara A. Solla, Todd K. Leen and Klaus-Robert Muller Eds, 2000.
- [15] . Vapnik, V. N., *The Nature of Statistical Learning Theory*, New York: Springer-Verlag, 1995.
- [16] Tax, D. M. J. y Duin, R.P.W., Support vector domain description. *Pattern Recognition Letters*, 20:1991-1999, 1999.
- [17] Borowska M, Oczeretko E, Mazurek A, Kitlas A, Kuć P, Application of the Lempel-Ziv complexity measure to the analysis of biosignals and medical images, *Annual proceedings of Medical Science*, Supplement 2, Vol. 50, 2005.
- [18] Aboy, Mateo, Hornero, Roberto, Abásolo, Daniel, y Álvarez Daniel, Interpretation of the Lempel-Ziv Complexity Measure in the Context of Biomedical Signal Analysis. *IEEE Transactions on Biomedical Engineering*, Vol. 53, No. 11, November, 2006.
- [19] Chang, Chih-Chung y Lin, Chih-Jen, LIBSVM: a Library for Support Vector Machines. [Online]. Disponible en: <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>, 2001.