

**ARTIFICIAL NEURAL NETWORKS AND ITS APPLICATION TO HIGH
ORDER STATISTICAL IN RECOGNITION OF PATHOLOGICAL ECG****REDES NEURONALES Y SU APLICACION DE ESTADISTICAS DE ALTO
ORDEN EN RECONOCIMIENTO DE ECG PATOLOGICOS****MSc. Camilo Londoño, MSc. Pedro A. Rangel, MSc. Eduardo Rodriguez****Universidad de los Andes**

Carrera 1 N° 18A 10, Bogotá, Colombia

Tel: +57(1) 339 9999 - 339 4949

E-mail: camilolondo@ieee.org, prangel@uniandes.edu.co, eduar-ro@ieee.org

Abstract: This paper deals with the Electrocardiogram (ECG) parameterization with recognition purposes. It is considered two types of ECG: healthy and sick. The classic analysis is focused in the most significant coefficients of the Fourier Transform (FT) to obtain its main characteristics, this paper intends to demonstrate that using high order statistical (HOS) instead of FFT it is possible to diminish the classification error for ECGs, with and without, the presence of white Gaussian noise.

Resumen: Este artículo trata sobre la parametrización del Electrocardiograma (ECG) con propósitos de reconocimiento. Se considera dos tipos de ECG: sano y enfermo. El análisis clásico se enfoca en los coeficientes más significativos de la Transformada de Fourier (FT) para la extracción de sus características, este artículo se propone demostrar que usando estadísticas de alto orden (HOS) en lugar de FFT es posible disminuir el error de clasificación para ECGs con y sin la presencia de ruido blanco Gaussiano

Keyword: Bicoherencias, Poliespectrum, Biespectrum, ECG, FFT, High Order Statistical (HOS), Artificial Neural Networks.

1. INTRODUCCION

La electrocardiografía es un método de diagnóstico no invasivo, ampliamente usado por los cardiólogos en la detección de problemas cardiovasculares. Los electrocardiogramas (ECG) son registros de la actividad eléctrica del corazón, obtenidos a través de electrodos conectados en áreas específicas del paciente. [8, 11].

En años recientes se han realizado un número considerable de investigaciones con el objetivo de diagnosticar automáticamente el estado del corazón.

Un amplio rango de estas han sido utilizadas, incluyendo reconocimiento de patrones estadísticos [10], análisis espectral, sistemas expertos y redes neuronales artificiales [12]. Con las redes neuronales se ha logrado robustez en la clasificación asociando señales irregulares con algún tipo de patrón de enfermedad. Otra técnica que es bien conocida y que arroja buenos resultados es el análisis estadístico del complejo electrocardiográfico. Un nuevo método para el reconocimiento de patrones son las estadísticas de alto orden [1] (HOS – *High Order Statistics*) que proveen datos adicionales para distribuciones no Gaussianas.

El objetivo de este artículo es sumar las características fundamentales de HOS y de redes neuronales artificiales para incrementar la confiabilidad en un sistema de diagnóstico automático de ECG contaminado con ruido blanco Gaussiano [10, 9].

2. DESCRIPCION DEL PROBLEMA

2.1 Enfoque Clásico

La interpretación de un ECG se hace a través de la lectura de un trazo electrocardiográfico por un cardiólogo mediante cierta técnica. En los últimos años se han desarrollado dispositivos médicos que identifican cambios de forma en la onda ECG. Sin embargo, algunas de estas tecnologías no han superado un criterio de error mínimo. Un buen rendimiento de un sistema de análisis automático del ECG depende principalmente de una detección confiable y exacta del complejo QRS así como de las ondas P y T. Figura.1.




Fig. 1: Onda ECG: Descripción de segmentos, intervalos y complejos

2.2 Enfoque Estadístico

Como se describió anteriormente, el complejo QRS varía considerablemente en un paciente sano. Si se construye un algoritmo de elección dura para complejo se estaría generando un error, por eso el análisis de una tendencia general de comportamiento de dicho complejo es la más acertada. El enfoque estadístico permite identificar un ECG sano en un rango elástico de acuerdo con las características estándar de la onda [10].

2.3 Estadísticas de Alto Orden

Históricamente, se han usado estadísticas de segundo orden en el análisis de procesos estocásticos; sin embargo, las estadísticas de segundo orden presentan deficiencias en el análisis cierto tipo de señales. Por ejemplo, la densidad

espectral de potencia no posee información acerca de la fase de un proceso estocástico. Por esta razón, en algunas aplicaciones es necesario extender el análisis a estadísticas de orden mayor.

Un proceso estocástico Gaussiano está totalmente definido por sus estadísticas de primer y segundo orden; y por tanto, su análisis puede ser realizado usando únicamente la auto-correlación y la densidad espectral de potencia; sin embargo, la mayoría de señales que se encuentran en el mundo real son de naturaleza no Gaussiana. Ejemplos de señales no Gaussianas son: la voz, las señales biomédicas. [1], [2], [3], [4].

3. DEFINICIONES

3.1 Momentos

El primer momento $M_{1,x}$ de un proceso $x(t)$ es simplemente su valor medio y provee una medida sobre la ubicación de su función densidad de probabilidad (PDF). El segundo momento es la varianza, la cual da una medida sobre la dispersión de la PDF. Existen también momentos de orden mayor, los cuales pueden encontrarse mediante los términos de la expansión en series de Taylor de la función generadora de momentos [1]. En general, el momento k -ésimo de un proceso estocástico $x(t)$ está definido como la esperanza del proceso multiplicado por $k-1$ versiones trasladadas de sí mismo, tal y como se muestra:

$$M_{2,x}(t) = E\{x(t)x(t+t)\} \quad (1)$$

$$M_{3,x}(t_1, t_2) = E\{x(t)x(t+t_1)x(t+t_2)\}$$

$$M_{k,x}(t_1, t_2) = E\left[x(t)\prod_{i=1}^{k-1}x(t+t_i)\right]$$

Los momentos poseen información acerca de la PDF de un proceso; sin embargo, el tratamiento matemático para calcular momentos es complicado y para algunas aplicaciones poco útil. Existe un conjunto de estadísticas las cuales poseen características matemáticas interesantes y que pueden ser aprovechadas en el análisis de señales. Este conjunto de estadísticas son los acumuladores.

3.2 Acumuladores

Los acumuladores pueden ser definidos por medio de una función generadora de acumuladores. Los acumuladores y los momentos están ampliamente relacionados. Los acumuladores de un proceso pueden ser calculados usando las relaciones entre los momentos y acumuladores. Sea $x(t)$ un proceso

con valor medio igual a cero, su acumulador de orden k , simbolizado por $C_{k,x}$ puede ser calculado usando las relaciones entre acumuladores y momentos. La ecuación 2 muestra esta relación para acumuladores de orden 2 y 3 [3].

$$\begin{aligned} C_{2,x}(t) &= E\{x(t)x(t+t)\} = M_{2,x}(t) = R_{xx}(t) \\ C_{3,x}(t_1, t_2) &= E\{x(t)x(t+t_1)x(t+t_2)\} = M_{3,x}(t_1, t_2) \end{aligned} \quad (2)$$

3.3 Poliespectro

El análisis espectral de procesos estocásticos empieza con la densidad espectral de potencia; no obstante, la densidad espectral de potencia no posee información sobre la fase del proceso. Para obtener información acerca de la fase de un proceso es necesario recurrir al poliespectro. Esto es una generalización de densidad espectral de potencia para estadísticas de alto orden. Así, la densidad espectral de potencia se calcula mediante la siguiente formula:

$$P(\mathbf{w}) = FT\{C_{2,x}(t)\} \quad (3)$$

Es posible encontrar el espectro de acumuladores superiores usando la transformada de Fourier en forma multi-dimensional. A estos espectros se les conoce con el nombre de poliespectros del proceso estocástico. Por tanto es posible hallar el poliespectro del acumulador de tercer orden, llamado biespectro:

$$B(w_1, w_2) = FT^{[2D]}\{C_{3,x}(t_1, t_2)\} \quad (4)$$

Cada poliespectro posee información relevante sobre el proceso. Por ejemplo, la densidad espectral de potencia posee información sobre la distribución de la energía de la señal en frecuencia, el biespectro posee información acerca de la fase de procesos asimétricos. [15]

3.3 Bicoherencia

La Bicoherencia es la función que esta definida a través de los poliespectros y es útil para comparar una función de densidad de probabilidad con otra.

$$bic(f_1, f_2) = \frac{S_{3,x}(f_1, f_2)}{\sqrt{S_{2,x}(f_1)S_{2,x}(f_2)S_{2,x}(f_1 + f_2)}} \quad (5)$$

La ecuación anterior describe la Bicoherencia de tercer orden que puede ser vista de una normalización del poliespectro de tercer orden y es vista como una función compleja.

3.4 Estadísticas de Alto orden para la caracterización de ECG

Uno de los problemas más importantes de la caracterización del ECG es decidir si el proceso es Gaussiano y lineal. Gaussiano significa que las estadísticas de segundo orden son suficientes para describir el proceso. La linealidad puede simplificar la representación de las señales, de aquí que los procesos puedan ser descritos de forma convolucional donde la entrada puede ser independiente e idénticamente distribuida (i.i.d.). Sea $x(n)$ un proceso estocástico y lineal, entonces usando el teorema de factorización espectral de Wold es posible representarlo usando [2]:

$$x(n) = \sum_k h(k)u(n-k) \quad (6)$$

Donde $u(n)$ es un proceso independiente e idénticamente distribuido. Empleando las estadísticas de segundo orden (correlación) es imposible diferenciar si este proceso es Gaussiano o no-Gaussiano; sin embargo, mediante los acumuladores de orden superior es posible identificar la naturaleza del proceso [5], usando el análisis de la Bicoherencia tenemos que si la señal es Gaussiana y el comparador es Gaussiano la ecuación (5) es igual a cero. En este caso al estimar el ECG normal, la Bicoherencia resulto ser una constante diferente de cero. Por lo cual estamos en el terreno de procesos no Gaussianos ideales para ser clasificados con estadísticas de alto orden.

4. REDES NEURONALES Y ESTADISTICAS DE ALTO ORDEN (HOS)

4.1 Redes Neuronales en medicina

El valor intrínseco de estas Redes subyace en el hecho de su enorme potencial como clasificador identificando patrones complejos y asignándolos a una clase en particular. El tipo más común de reconocimiento consiste en tres (3) capas: la capa de entrada, la escondida y de salida, conectadas en secuencia.

La red neuronal es capaz de generar un mapa no lineal de funciones y representar la mayoría de desordenes de ECG a través de clases de salida. Entonces, para una medición preliminar se usará esta técnica, con el fin de comparar la robustez en términos de extracción de características con HOS. [9]

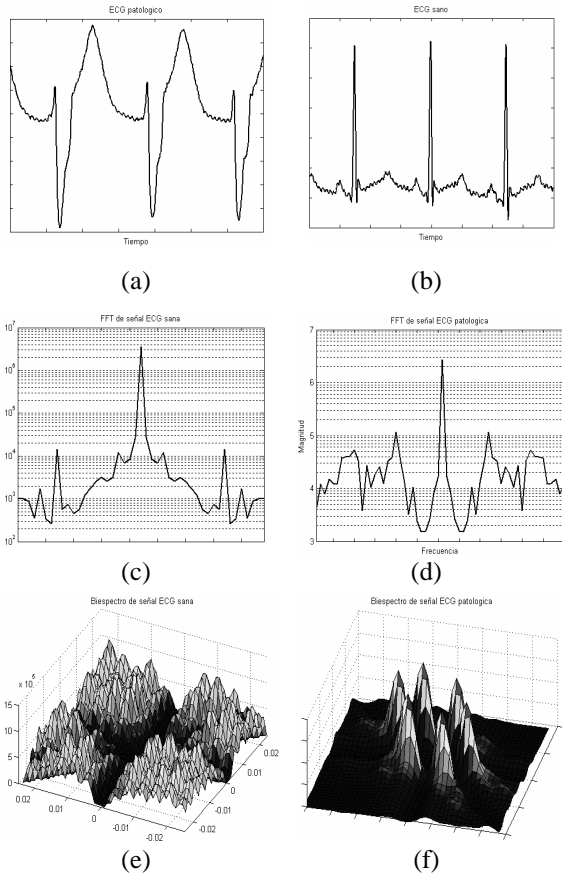


Fig. 2: (a) EGC normal, (b) EGC patológica de un paciente que presenta una contracción ventricular prematura. (c) FFT de EGC normal (d) FFT de (b) (e) Biespectro de (a), (f) Biespectro de (b).

Para una evaluación preliminar se tiene en cuenta una red neuronal de tres capas con $n+1$ entradas, $p+1$ neuronas en la capa escondida y $m+1$ salidas. Utilizaremos la red Perceptron Multi Nivel (MLP).




Fig.3: Red neuronal con una capa escondida

La eficiencia de este clasificador depende de un número de factores incluida el entrenamiento de la red. En el estudio desarrollamos un modelo de predicción que indica en que punto de entrenamiento debe parar para asegurar la máxima generalización.

4.2 Método

Dos modelos de extracción de características son presentados, uno basado en la Transformada de Fourier y el otro en Estadísticas de Alto Orden, ambas técnicas pueden ser ampliamente exploradas con las herramientas de MATLAB®, HOS puede ser evaluado con Toolbox HOSA desarrollado por Swami (el mismo autor de [6]).

4.3 Implementación

En un esfuerzo para asegurar un modelo de predicción correcto, se ha empleado un sistema de red neuronal con topología MLP, durante el desarrollo se exploraron varias arquitecturas (en términos de número de neuronas en cada capa). Fue empleado el algoritmo de *backpropagation*. La capa escondida tiene 10 neuronas, todas las neuronas utilizan una función de activación sigmoideal.

4.4 Datos de Entrenamiento

Los datos de entrenamiento utilizados en este proyecto provienen de la base de datos MIT-BIH. Esta base de datos es mantenida por la División de Harvard-MIT de Ciencias de la Salud y Tecnología. Ver fig. 4.




Fig. 4: Onda ECG Normal

4.5 Pre-procesamiento

El pre-procesamiento es un factor clave en el análisis de las redes neuronales, ya que permite adaptar los datos a la entrada de la red. El error de generalización puede depender del procedimiento que se utilice, en este caso se enfrenta al eficiencia de la FFT versus las características del Biespectro producido por HOS.

4.6 Simulaciones FFT versus HOS

La eficiencia de estos clasificadores, depende de varios factores, los cuales incluyen la arquitectura

de la red, el método de entrenamiento y el tipo de características que se extraen de la señal ECG. A continuación se expone un método de clasificación de señales ECG usando redes neuronales, en donde la extracción de las características de la señal ECG se realiza utilizando estadísticas de alto orden.

Este esquema de clasificación es comparado con el enfoque clásico de caracterización de señales ECG usando FFT. Ver Fig. 6. Es posible entrenar una red neuronal usando como entrada los coeficientes más representativos de su transformada rápida de Fourier.

Es bien conocido que la mayor parte de la información de una señal ECG se encuentra concentrada entre los 13Hz y los 50Hz. Usando los coeficientes de la FFT que representan esas frecuencias de la señal es posible caracterizar en forma eficiente a la señal ECG.

Con el objeto de comparar el enfoque clásico con el propuesto, se entrenó un perceptrón de dos capas, con 10 neuronas en la capa escondida, y usando como entrada los 19 coeficientes más específicos de la FFT de diferentes señales ECG.

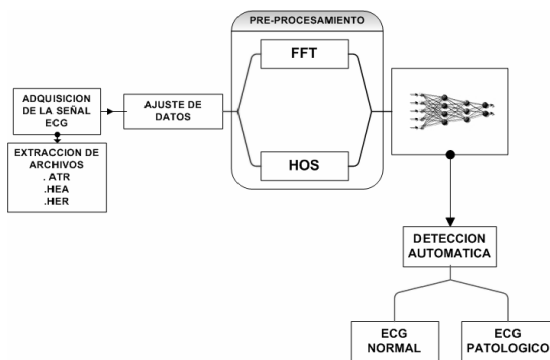


Fig. 5: Diagrama de Bloques del proceso de Caracterización y reconocimiento del patrón ECG Sano y ECG Patológico

El objetivo de la red neuronal era clasificar las señales ECG en señales sanas y patológicas. Con este tipo de red se obtuvo un error de clasificación sobre los datos de 5%, y un error estimado de generalización de 3%.

Para el entrenamiento de la red se utilizaron 10000 señales ECG de la base de datos del MIT-BIH. La Figura. 6 muestra el error sobre el conjunto de prueba y entrenamiento contra el número de iteraciones.

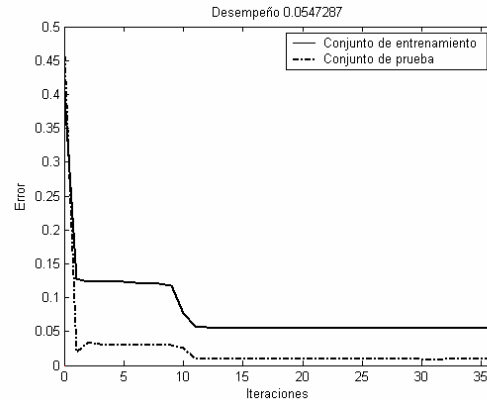


Fig. 6: Entrenamiento de red neuronal usando como parámetros de entrada los coeficientes más representativos de la FFT de las señales ECG

Cuando las señales de prueba se contaminan con un error de potencia igual al 1% de la potencia de la señal original el error de clasificación crece hasta el 8.1%, para un ruido de potencia igual al 5% de la potencia de la señal original, el error crece a 16.8% y para señales contaminadas con un ruido de potencia igual al 10% de la potencia de la señal original, el error crece a 27%.

A continuación, se entrenó la misma red neuronal usando los 16 coeficientes más representativos del bispectro. Usando estos datos en la entrada de la red, para los mismos datos que el caso anterior, se obtuvo un error de clasificación sobre los datos de entrenamiento del 3%. Para esta red, el error estimado de generalización fue del 1%. La Fig. 7. muestra el error de los datos de prueba y entrenamiento contra el número de iteraciones.




Fig. 7: Entrenamiento de la red neuronal usando como parámetros de entrada los coeficientes más representativos del bispectro de las señales ECG

Al evaluar esta red, con datos de entrada contaminados por ruido de potencia igual a 1%, 5% y 10% se obtienen errores estimados de 4.2%,

6.1% y 8.9%, respectivamente. Una de las características más importantes del biespectro de una señal es que no se afecta cuando dicha señal es contaminada con ruido blanco Gaussiano; es posible utilizar el biespectro debido a que la bicoherencia es diferente de cero.

La Fig. 8. muestra, de arriba hacia abajo, cuatro señales electrocardiográficas contaminadas con ruido blanco Gaussiano de potencia igual a 10%, 5%, 1% y 0% de la potencia de la señal original. Al entrenar una red neuronal cuyas entradas son los principales coeficientes de la señal contaminada con ruido, se obtienen errores de clasificación de 24.3%, 16.5% y 7.9%, respectivamente.




Fig. 8: ECGs contaminados con un ruido blanco Gaussiano de potencia igual a 10%, 5%, 1% y 0% de la potencia de la señal

Al realizar la misma clasificación de las señales contaminadas con ruido usando como entradas los coeficientes más representativos del biespectro, se obtienen resultados ostensiblemente mejores. Para la señal contaminada con ruido blanco de potencia igual a 10% de la potencia de la señal original, se alcanza un error de 10.9%. La Figura. 9 muestra el error de clasificación contra el número de iteraciones en el entrenamiento de la red.

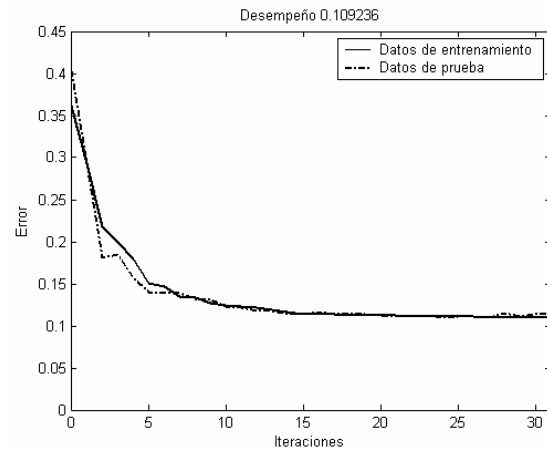


Fig. 9: Resultados del entrenamiento al contaminar la señal con un ruido blanco Gaussiano con potencia igual al 10% de la potencia de la señal

Equivalentemente, para señales contaminadas con ruido de potencia igual al 5% y 1% de la potencia de la señal original, se obtiene las Figura 10. de error contra número de iteraciones. Para señales ECG contaminadas con ruido del 5% se obtiene un error del 6.5%, mientras que para señales contaminadas con ruido del 1% se obtiene un error del 5%.




Fig. 10: Resultados del entrenamiento al contaminar la señal con un ruido blanco Gaussiano con potencia igual al 5% de la potencia de la señal

Los resultados para las redes entrenadas usando datos sin contaminar por ruido blanco Gaussiano son mostrados en la Tabla 1.

**Tabla 1. Desempeño para las redes entrenadas
empleando datos sin contaminar**

Red entrenada	$e(z)$ ruido 0%	$e(z)$ ruido (1%)	$e(z)$ ruido (5%)	$e(z)$ ruido (10%)
usando FFT	5.4 %	8.1%	16.8%	27%
usando Biespectro	3.1%	4.2%	6.1%	8.9%

Mientras que los resultados para las redes usando datos contaminados por ruido son mostrados en la Tabla 2. Donde $e(z)$ representa el error de clasificación.

**Tabla 2. Desempeño para las redes entrenadas
empleando datos contaminados**

Red entrenada	$e(z)$ (1%)	$e(z)$ (5%)	$e(z)$ (10%)
usando FFT	7.9%	16.5%	24.3%
usando iespectro	5%	6.5%	10.9%

5. CONCLUSIONES

Se entrenó una perceptrón con dos capas, 10 neuronas en la capa escondida y una neurona de salida, usando dos diferentes características de la misma señal ECG. En el primer enfoque se entrenó la red usando la FFT de la señal ECG, y en el segundo se entreno usando el Biespectro de la misma señal. El error de generalización fue estimado mediante validación cruzada. Primero, se validó el desempeño de las redes usando señales de prueba sin contaminar, luego se valido el desempeño usando señales de prueba contaminadas con ruido blanco Gaussiano de diferentes potencias. El error de clasificación con el procesamiento basado en FFT resultó ser muy sensible a la relación señal a ruido (SNR), mientras que el procesamiento basado en HOS presentó un mejor desempeño.

En el artículo se demostró que es posible disminuir el error de clasificación de una red neuronal con técnicas de pre-procesamiento estadístico.

Es posible extender las clases de salida a diferentes patologías cardiacas como: arritmias ventriculares, bloqueos de rama, isquemias, etc. y con la ayuda de HOS hacerlas poco sensibles al Ruido Blanco Gaussiano. En general, esta aproximación se puede extender a otras señales fisiológicas.

REFERENCIAS

- [1] Nimias, C. L. Petropulu. A. P “Higher Order Spectra analysis”, PTR Prentice Hall, New Jersey, 1993.
- [2] Priestley, M. B. “Spectral Analysis and Time Series”, London: Academic Press Harcourt Brace Jovanovich, 1992.
- [3] Mendel, J.M “Tutorial in Higher-Order Statistics (Spectra) in signal Processing and System Theory: Theoretical Results and Some applications” Proceedings of the IEEE, Vol, 79 No 3 March 1991. pp. 277-305.
- [4] Nikias, C. L. Raghuvver, M.. “Biespectrum estimation: A digital signal processing framework”, Proc. IEEE, vol. 75, pp. 876-891, 1987.
- [5] Hinich, M.J. “Testing for Gaussianity and linearity of a stationary time series,” J. Time Series Analysis, Vol. 3, pp. 169-76, 1982.
- [6] Swami, A., “Some new results in higher-order statistics,” Proc. Intl. Signal Processing Workshop on Higher-Order Statistics, Chamrousse, France, pp. 135-38, July 1991.
- [7] Gallagher. J. C. “Evolution of Dynamical Neural Network Arrays to Correct Arrhythmias in a Simulated Human Heart”. Department of Computer Science and Engineering Wright State University, Dayton, OH 45435-0001.
- [8] Manintveld J. C. “Automated ECG Análisis using Weighless Neural Networks” Master Thesis: Delft University of Technology, The Netherlands. June 1996.
- [9] Jakubowski, J. Kwiatos, K. Chwaleba A., and Osowski S., “Higher Order Statistics and Neural Network for Tremor Recognition”, IEEE Transactions on Biomedical Engineering, vol. 49, no. 2, February 2002.
- [10] Sarle. W. S. “Neural Networks and Statistical Models” Proceedings of the Nineteenth Annual SAS Users Group International Conference, April, 1994.
- [11] Prasad, G.K. Sahambi J. S, “Classification of ECG Arrhythmias using Multi-Resolution Analysis and Neural Networks”, Department of Electronics & Communication Engineering Indian Institute of Technology Guwahati Guwahati, Assam – 781039.
- [12] Moreno A., Rutllán M., “Integrated polispectrum on speech recognition”, Universidad Politécnica de Cataluña Dep.

Teoría de la Señal y Comunicaciones,
Barcelona, Spain, e-mail:
asuncion@gps.tsc.upc.es

- [13] Fogel, DB: *What is evolutionary computation?*. *IEEE Spectrum* 2000, **37**:26–32.

- [14] Gaona. A, Olea D. “Estadísticas de alto orden aplicadas a la clasificación de señales ECG”, Universidad de Los Andes, 2003.

- [15] Londoño C.A, Rangel P.A “Principales Aplicaciones De Las Estadísticas De Alto Orden (HOS)”, Universidad de Los Andes. 2003.