

# Hacia la clasificación de fonocardiogramas utilizando descriptores caóticos y estadísticos

**Carlos Antonio Osorio Maceda**

Tecnológico de Monterrey, Campus Puebla,  
Vía Atlixcáyotl 2301, Reserva Territorial Atlixcáyotl, C.P. 72431, Puebla, México

**Hugo G. González-Hernández**

Tecnológico de Monterrey, Campus Puebla,  
Vía Atlixcáyotl 2301, Reserva Territorial Atlixcáyotl C.P. 72431, Puebla, México  
*hgonz@itesm.mx*

## Resumen

En este trabajo, tres descriptores: la dimensión de correlación, el exponente de Lyapunov y la entropía aproximada, son calculados a partir de series de tiempo procedentes de mediciones de fonocardiogramas, con el propósito de entrenar una red neuronal auto-organizada para clasificar afecciones cardíacas. El uso de la red neuronal, en conjunto con descriptores caóticos y estadísticos, muestran un buen desempeño y capacidad para lograr una segmentación entre clases.

**Palabra(s) Clave(s):** análisis de series de tiempo, entropía aproximada, fonocardiograma, reconstrucción del atractor, red neuronal auto-organizada, teoría de caos.

## 1. Introducción

En la actualidad el ser humano se ha enfocado en desarrollar áreas científico-técnicas que le permita generar procesos multidisciplinarios en donde las bases del conocimiento no permanezcan afines a una sola área. El tratar a los problemas con

este enfoque, permite contar con un mayor número de herramientas para el tratamiento o análisis de sistemas, tal es el caso del estudio de las señales biológicas, las cuales a lo largo de los últimos años han recibido un gran interés debido a su comportamiento irregular en el tiempo, lo que conlleva a que se trate de un sistema dinámico altamente impredecible.

El interés en su estudio ha derivado en la generación de conocimiento y herramientas que tratan de caracterizar y cuantificar cada una de las propiedades que conforman a las señales. De esta manera surgen algoritmos de análisis que buscan darle solución a ello, permitiendo así contar con un estudio en tiempo real de las mismas. Trabajos como los reportados en [1], [2], y [3] describen resultados en el análisis de señales del corazón, pulmón y cerebro en donde han sido empleadas técnicas estocásticas, Teoría de Caos y análisis en tiempo y frecuencia para modelar y extraer características de las mismas.

Dentro de los resultados encontrados en el análisis de señales biológicas se encuentran herramientas derivadas del estudio del Caos que, en conjunto con paradigmas de aprendizaje, han demostrado un porcentaje de efectividad elevado en la obtención y clasificación de parámetros para la caracterización de señales. Trabajos como los reportados en [4] y [5] han expuesto una comparación entre distintos métodos para la clasificación de cardiopatías y cuyos resultados arrojan una tendencia a lograr un mejor resultado al utilizar técnicas como máquinas de soporte vectorial y redes neuronales en conjunto con elementos caóticos. Estos hechos abren la oportunidad para la aplicación de análisis como [6] y [7], en la implementación de un algoritmo capaz de clasificar señales biológicas, específicamente del corazón, para la prevención o tratamiento oportuno de enfermedades cardíacas.

Este trabajo aborda el estudio de señales del corazón, particularmente fonocardiogramas, para su clasificación, mediante la extracción de descriptores caóticos y de uso de una red neuronal auto-organizada, con la finalidad de identificar afecciones cardíacas.

Este documento se encuentra organizado de la siguiente forma: la sección número dos presenta información técnica acerca de la adquisición de las señales del corazón y las afecciones que son el objeto de estudio. Así mismo, se introduce los algoritmos de Grassberger-Procaccia [8] y Rosenstein [9] para el cálculo de la dimensión de correlación y el exponente de Lyapunov respectivamente, se describe la Entropía Aproximada [10] y se detalla cómo se utilizan estos descriptores para entrenar la red neuronal. Los resultados obtenidos de la aplicación de la red son analizados en la sección tres. Finalmente se presentan algunas conclusiones.

## **2. Desarrollo**

### **2.1. Adquisición de señales**

Para el objeto de estudio se han seleccionado dos bases de datos provenientes de [11], las cuales se encuentran conformadas por archivos de audio cuya longitud varía entre 1 a 30 segundos y proceden de un estudio clínico en hospitales en el que se empleó un estetoscopio digital llamado DigiScope. A su vez, estos archivos se encuentran segmentados en dos categorías: señales de corazón normales y con murmullo.

La primera categoría se trata de sonidos provenientes de corazones sanos y se conforma por 200 muestras, mientras que la segunda categoría contiene 92 modelos de sonidos inusuales en el ciclo del latido del corazón, cuyas características se explican en [12]. Ambas categorías han sido obtenidas de niños y adultos en diferentes estados de relajación y excitación mediante la técnica de auscultación, descrita en [13], y pueden contener ruidos derivados de la respiración o del ambiente en el que se realizan las pruebas. Algunos ejemplos de las señales a analizar son mostrados en (Fig. 1).

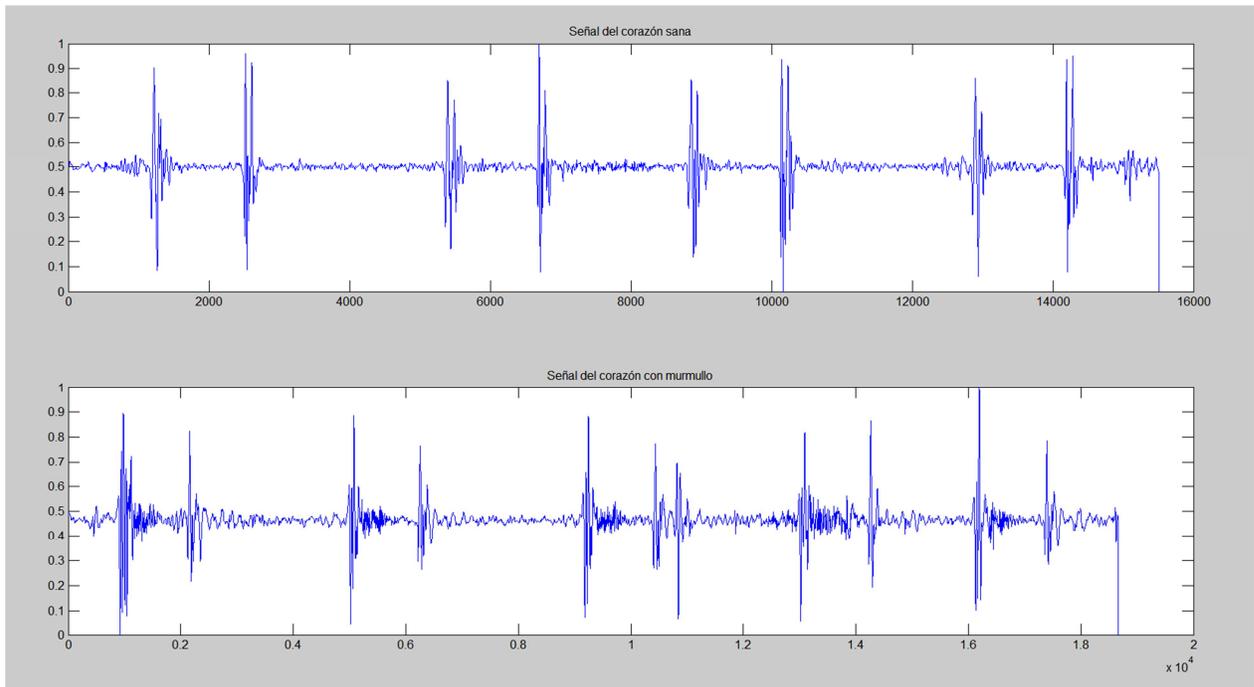


Fig. 1. Señal de corazón sana y con murmullo.

## 2.2. Reconstrucción del atractor

Antes de aplicar el algoritmo de Grassberger-Procaccia [8] para calcular el exponente de Lyapunov, es necesario reconstruir la dinámica del espacio de estados a partir de la serie de tiempo. Para ello se hace uso del método Coordenadas Retrasadas [14], en donde se crean vectores  $D$ -dimensionales con retrasos de la señal original:

$$y(n) = [x(n), x(n + \tau) \dots, x(n + (D - 1)T)] \quad (1)$$

En donde  $T$  describe la separación en múltiplos del tiempo de muestreo entre los valores de la serie de tiempo que son utilizados como coordenadas para cada vector y que se denota como el tiempo de retraso, y  $D$  es la dimensionalidad de los vectores reconstruidos, llamada dimensión de empotramiento. Para calcular estos parámetros en (1), se hace empleo de los algoritmos de Falsos Vecinos Cercanos y Promedio de Información Mutua [14]. Obteniendo de esta manera para la categoría de señales de corazón sanas  $D = 4$  y para la categoría de señales con murmullo  $D = 3$ . Mientras que

el tiempo de retraso en la primera categoría varía entre  $T = 19$  a  $T = 21$  y para la segunda se obtienen valores entre  $T = 14$  a  $T = 20$ .

### 2.3. Dimensión de correlación

Otorga un significado físico a las regiones de un atractor al resaltar las órbitas que son visitadas con mayor frecuencia, obteniendo así una cuantificación precisa de la naturaleza fractal del atractor [15]. Para ello, se construye una función  $C(r)$  que denotará la probabilidad de que dos puntos, seleccionados arbitrariamente de la trayectoria de la reconstrucción del atractor, se encuentren en el vecindario de un elemento volumétrico  $D$ -dimensional con radio  $r$  [8]. Esta función es entonces normalizada de tal forma que cuando  $r$  es lo suficientemente grande, se obtiene  $C(r) = 1$ . Al asumir que se toman  $N$  puntos del espacio de estados de la trayectoria, se tiene que:

$$C(r) = \frac{2}{N(N-1)} \sum_{j=1}^N \sum_{i=j+1}^N \theta(r - r_{ij}) \quad (2)$$

En la ecuación (2)  $\theta$  representa la función Heaviside y  $r$  es la separación entre los puntos  $i$  y  $j$  que se calcula a través de la norma Euclidiana. Al graficar  $\log(C(r))$  contra  $\log(r)$  se produce una línea recta cuya pendiente en los límites de valores pequeños de  $r$  y valores grandes de  $N$  es la dimensión de correlación:

$$D_2 = \lim_{r \rightarrow 0} \lim_{N \rightarrow \infty} \frac{d \log(C(r))}{d \log(r)} \quad (3)$$

### 2.4. Exponente de Lyapunov

Representa una medida cuantitativa de la divergencia exponencial de las trayectorias que indica la sensibilidad o dependencia de los estados futuros de un sistema bajo ciertas condiciones iniciales [9]. Para un sistema determinista, si su valor es positivo entonces, dos trayectorias que en un inicio se encontraban muy próximas, se separan en el tiempo, indicando comportamiento caótico en el sistema.

De esta manera una perturbación infinitesimal inicial crecerá exponencialmente y, a la razón de crecimiento que tenga, se le conoce como exponente de Lyapunov:

$$\lambda_i = \frac{1}{KT} = \sum_{k=1}^K \ln \|\delta y_i^k\| \quad i = 1, \dots, n \quad (4)$$

Donde  $\lambda_i$  es el  $i$ -ésimo exponente de Lyapunov,  $T$  es el tiempo entre muestras,  $y_i$  es la  $i$ -ésima componente de  $y$  y  $\delta y$  es la desviación en la trayectoria de dos condiciones iniciales arbitrariamente cercanas.

Rosenstein [9] desarrolló un algoritmo para el cálculo del máximo exponente de Lyapunov a partir de una serie de tiempo. El primer paso consiste en la reconstrucción del atractor. Después de esto se calcula el vecino más cercano para cada uno de los vectores que representa la trayectoria del atractor y el máximo exponente de Lyapunov es estimado como la tasa media de las separaciones de estos vecinos. Al asumir una separación determinada por el máximo exponente de Lyapunov ( $\lambda$ ), entonces al tiempo  $t$ , la divergencia promedio será:

$$d(t) \sim C e^{\lambda(i\Delta t)} \quad (5)$$

En donde  $d(t)$  es el promedio de la divergencia de la trayectoria en el tiempo  $t$ ,  $C$  es una constante de normalización que multiplica a la separación inicial entre trayectorias del atractor. Partiendo de (5), se llega a que la distancia obtenida de los vecinos cercanos será igual a la distancia mínima inicial.

$$d_j \approx C_j e^{\lambda(i\Delta t)} \quad (6)$$

Por lo que realizando un ajuste por mínimos cuadrados se busca la línea  $p$  que mejor se ajuste, obteniendo así el máximo exponente de Lyapunov.

$$p(i) = \frac{1}{\Delta t} \ln d_j(i) \quad (7)$$

## 2.5. Entropía aproximada

Es un indicador no lineal que permite cuantificar el grado de complejidad de un sistema a partir de una serie de tiempo. Permite discriminar señales en función de su regularidad sin tener en cuenta el modelo de sistema que las generó, en consecuencia, es independiente de la naturaleza de la señal [10]

La Entropía Aproximada se calcula al medir la semejanza logarítmica entre patrones consecutivos de longitud  $m$  que pertenecen a una secuencia  $x(n)$  de  $N$  muestras y que tengan una diferencia menor que  $r$  veces la desviación estándar de  $x(n)$ .

De esta manera, al tener  $N$  muestras de la serie  $x(n)$ , para calcular la entropía aproximada primero se generan  $N-m+1$  patrones denominados  $X(1) \dots X(N-m+1)$ , con  $X(i) = [x(i), x(i+1), \dots, x(i+m-1)]$  donde  $i = 1, 2, \dots, N-m+1$ , representando  $m$  valores consecutivos de  $x(n)$  y se obtiene la frecuencia de patrones similares de longitud  $m$  con tolerancia  $r$  a través de:

$$C_r^m(i) = \frac{d[X(i), X(j)] \leq r}{N-m+1}, j = 1, 2, \dots (N - m + 1), \forall j \neq i \quad (8)$$

Donde  $d[X(i), X(j)]$  cuantifica la cantidad de patrones similares separados  $j$  veces un máximo de  $m$  muestras que tienen una diferencia menor a la tolerancia  $r$ , así:

$$d[X(i), X(j)] = \max_{k=1, 2, \dots, m} (x(i+k-1) - x(j+k-1)) \quad (9)$$

Se calcula el logaritmo de cada  $C_r^m(i)$  y se promedia para todas las muestras  $N$ :

$$C_r^m = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} C_r^m(i) \quad (10)$$

Finalmente, se aumenta la dimensión en  $m+1$  y se calcula nuevamente (10). Al ser un número finito, la entropía aproximada se obtiene mediante:

$$ApEn(x(n), m, r, N) = C_r^m - C_r^{m+1} \quad (11)$$

## 2.6. Clasificación de la información

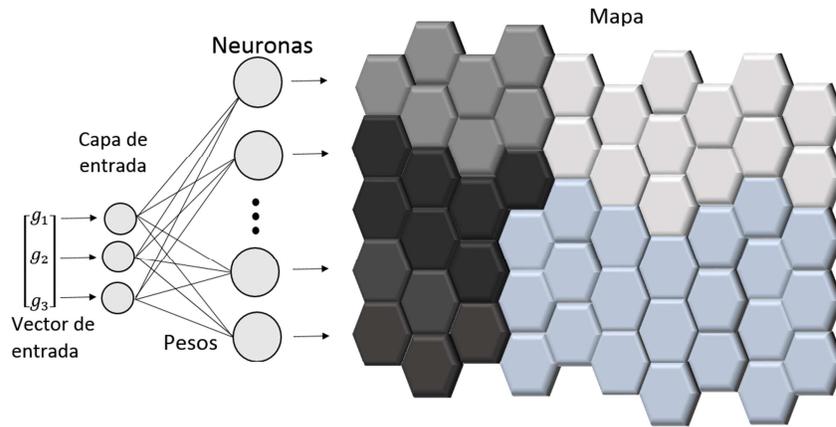
En esta sección se aborda el problema de la clasificación de las dos clases de señales del corazón con el uso de una red neuronal auto-organizada. El objetivo es dividir el espacio de estados que contiene las características en regiones separadas para cada una de las diferentes clases de señales del corazón a través de un vector de clases para el entrenamiento de la red. Para ello se crea un vector  $\mathbf{g} = [g_1, g_2, g_3]$  con tres componentes:

$g_1$ : *Dimensión de Correlación*

$g_2$ : *Máximo exponente de Lyapunov*

$g_3$ : *Entropía aproximada*

Este vector es empleado como entrada para el entrenamiento de la red neuronal de la (Fig. 2) El funcionamiento consiste en inicializar los pesos entre capas con valores pequeños y a través de un aprendizaje no supervisado y competitivo se ajustan los pesos para cada uno de los patrones de entrada, siendo que la neurona con el menor valor de la función discriminante será la que determine la ubicación espacial de la topología del vecindario que contiene a las neurona excitadas, proporcionando así la base para la cooperación entre las neuronas vecinas. Finalmente, las neuronas excitadas se adaptan al ajustar sus pesos de conexión en relación a la neurona ganadora, de tal forma que la respuesta a un patrón de entradas similares es alcanzado.



**Fig. 2. Esquema de red neuronal auto-organizada.**

El esquema de la red neuronal en la (Fig. 2) fue implementado utilizando Matlab® R13b y su Toolbox para redes neuronales. Se seleccionó un total de 25 neuronas para la capa oculta y a continuación se presentan los resultados obtenidos.

### 3. Resultados

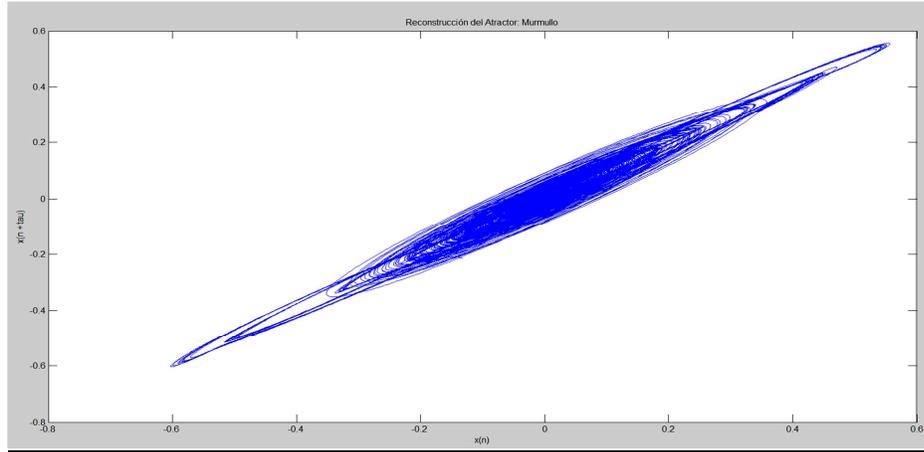
Los resultados de la aplicación de los algoritmos de la sección III y clasificación IV son presentados a continuación. Primero, se muestran los resultados en la extracción de los descriptores, comenzando por la reconstrucción de Atractor para la obtención de la dimensión de correlación y máximo exponente de Lyapunov, ejemplo de esta reconstrucción se pueden observar de la (Fig. 3) a la (Fig. 8), seguido a esto, se prosigue con un análisis de los resultados del parámetro conocido como Entropía Aproximada. Finalmente, en la a (Fig. 11) y (Fig. 12) se presentan los resultados de la clasificación.

#### 3.1. Extracción de descriptores

La reconstrucción del atractor para la obtención de la dimensión de correlación arrojó que para la señal de corazón sana los valores oscilan entre 1.4215 a 1.8081, mientras

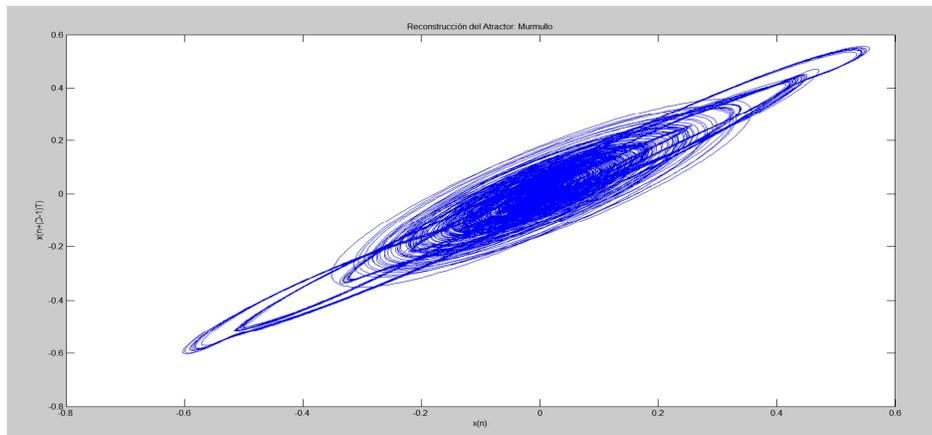
que para la señal con murmullo en el corazón se obtuvo un rango entre 1.5547 a 1.8785.

El análisis para la obtención del máximo exponente de Lyapunov muestra que para las señales de corazón sano se tiene un rango de valores mínimo y máximo entre 0.01367 a 0.05041; y para señales con murmullo se tiene que el valor máximo es 0.04664 y el valor mínimo es de 0.00666.

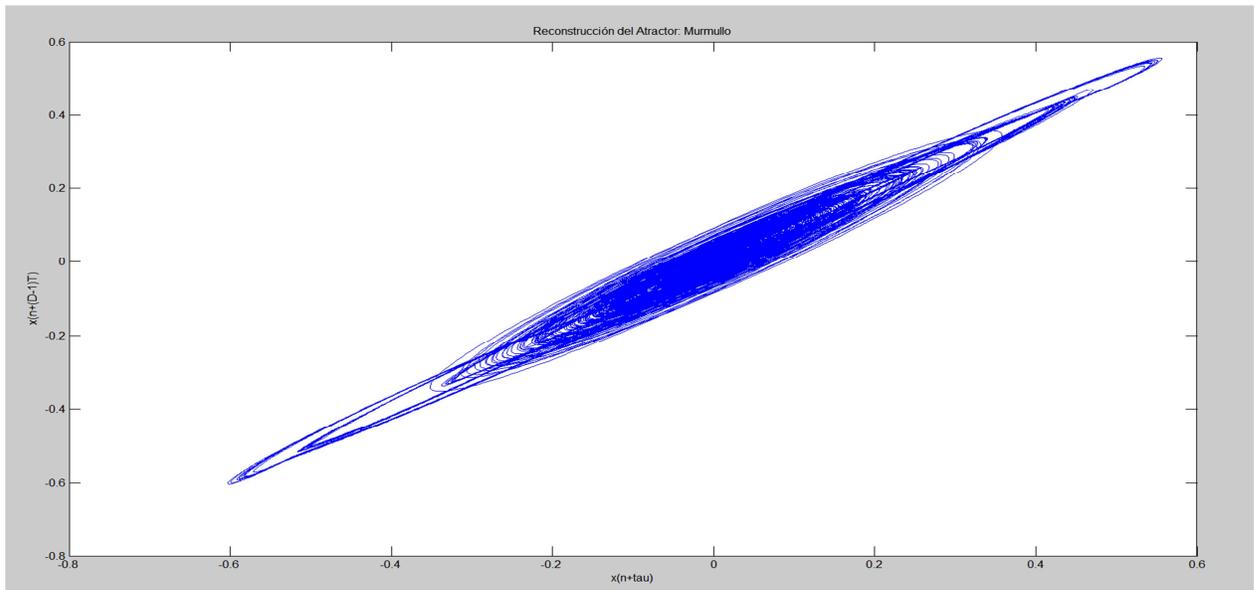


**Fig. 3. Reconstrucción del atractor, señal del corazón con murmullo:**

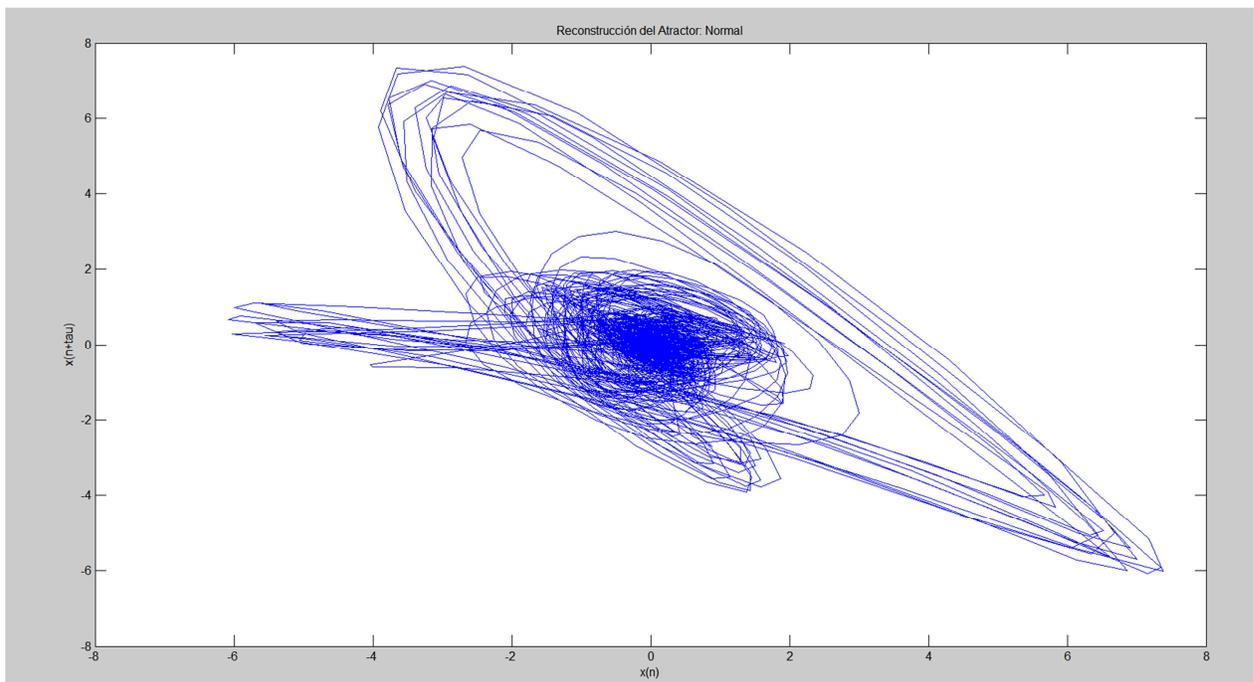
**Proyección plano X-Y.**



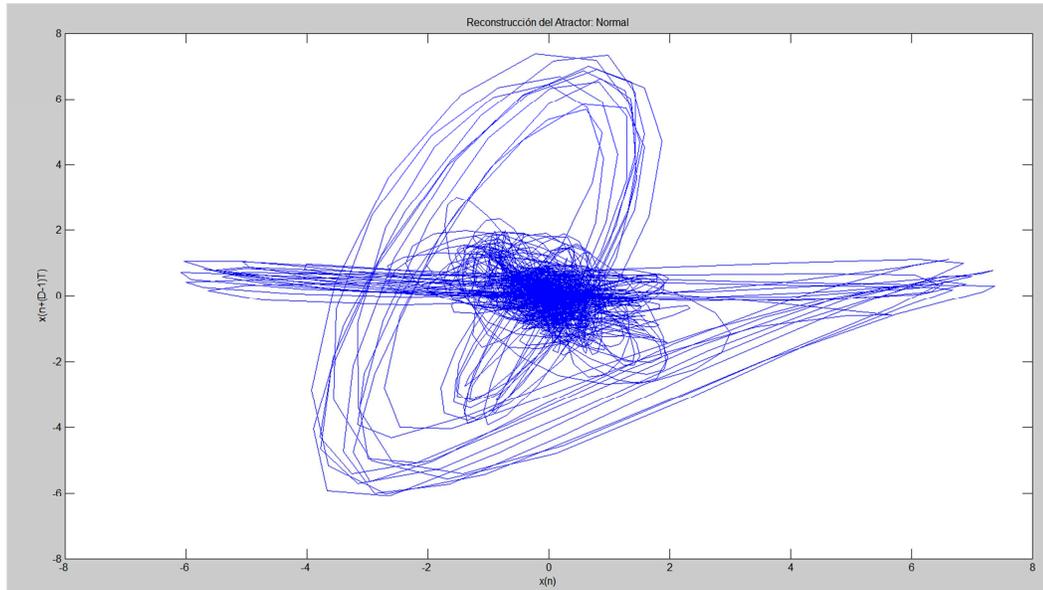
**Fig. 4. Reconstrucción del atractor, señal del corazón con murmullo: Proyección plano X-Z.**



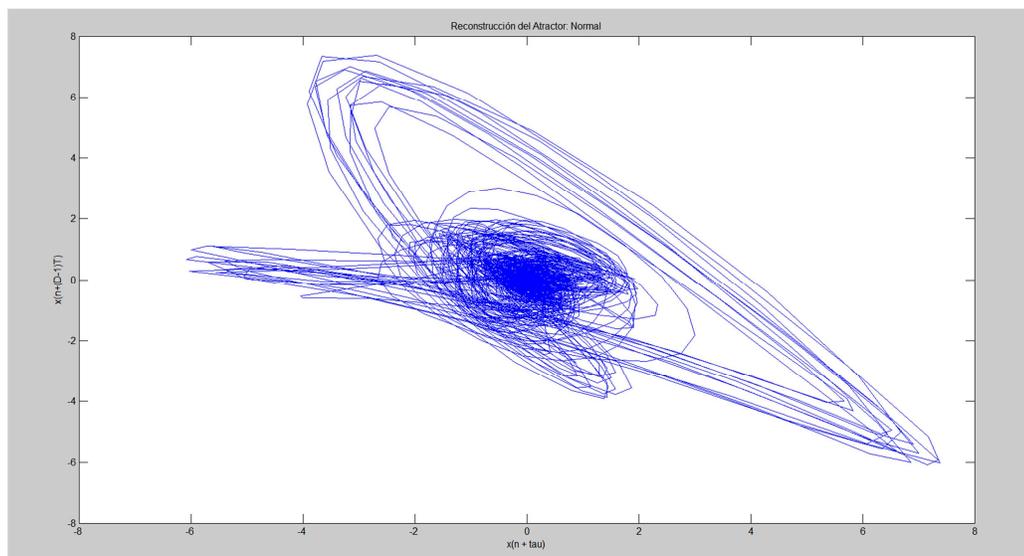
**Fig. 5. Reconstrucción del atractor, señal del corazón con murmullo: Proyección plano Y-Z.**



**Fig. 6. Reconstrucción del atractor, señal del corazón sano: Proyección plano X-Y.**



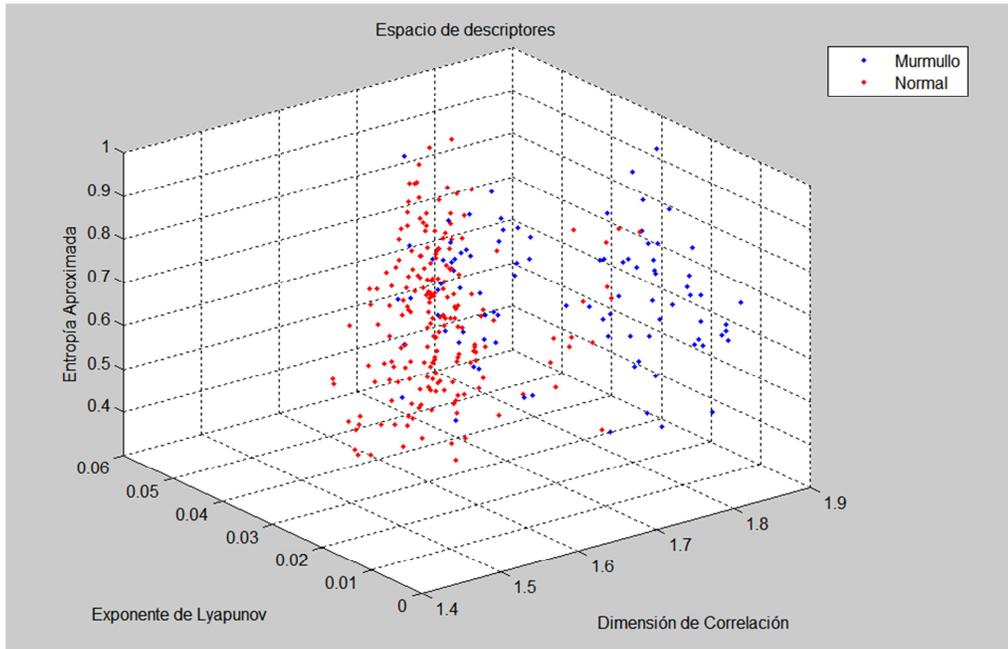
**Fig. 7. Reconstrucción del atractor, señal del corazón sano: Proyección plano X-Z.**



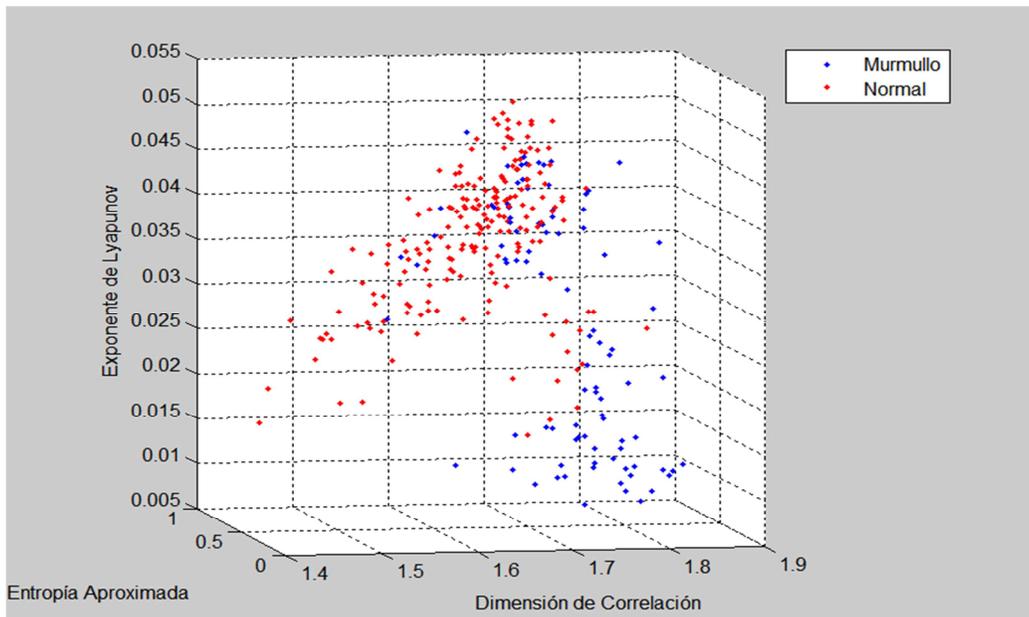
**Fig. 8. Reconstrucción del atractor, señal del corazón sano: Proyección plano Y-Z.**

El método de entropía aproximada muestra una variación para señales de corazón sano entre 0.32489 a 0.92903 y para señales con murmullo se tiene un rango entre 0.38198

a 0.95668. En la (Fig. 9) y (Fig. 10) se muestra la distribución de estos descriptores para todas las muestras analizadas.



**Fig. 9. Espacio de descriptores.**



**Fig. 10. Espacio de descriptores.**

### 3.2. Clasificación

Los resultados del entrenamiento de la red neuronal se muestran en la (Fig. 11) y (Fig. 12). En la (Fig. 11) se aprecia el plano de los pesos para cada una de las entradas del vector  $\mathbf{g}$ , esta figura es una representación de la forma en que se distribuyen cada una de los pesos que conecta a cada una de las entradas con las neuronas que conforma la red neuronal, si el patrón de entrada es muy similar, entonces las entradas se encuentran altamente correlacionadas. De esta forma, se puede apreciar que para la entrada  $g_1$  y  $g_2$  se logra encontrar una similitud entre entradas que denota una segmentación entre las clases de señal del corazón sano y con murmullo, mientras que para la entrada  $g_3$ , las entradas no generan una aglomeración que permita denotar una correlación entre clases, lo que ocasiona errores en el proceso de segmentación. Así mismo, en la (Fig. 12) se visualizan las distancias entre las conexiones de los pesos con las neuronas que generan la red neuronal, algunas de estas muestras se encuentran demasiado cercanas una de otras, lo que contribuye a obtener errores en la clasificación de las clases.

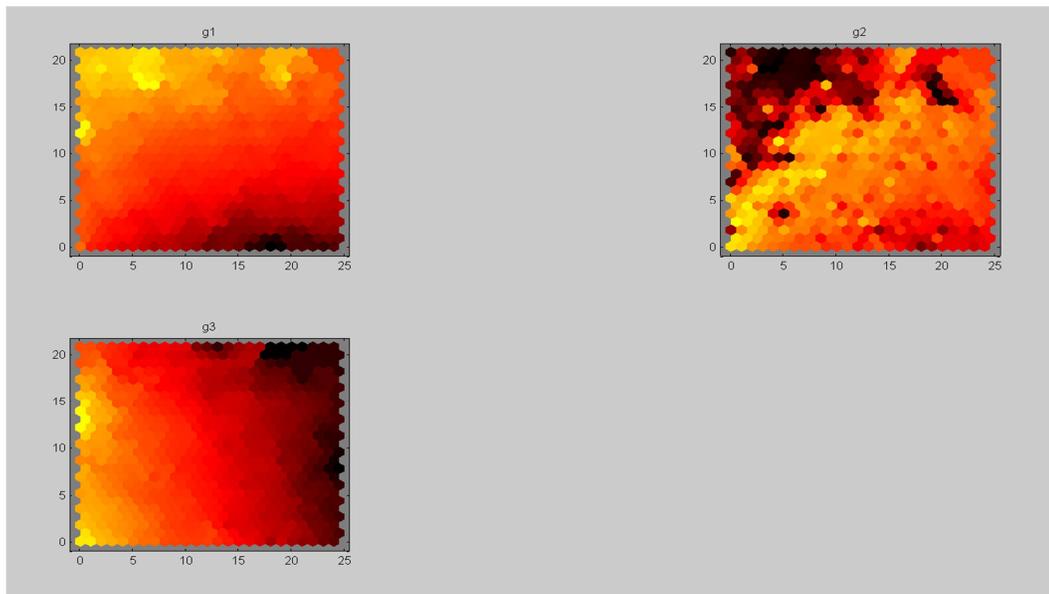
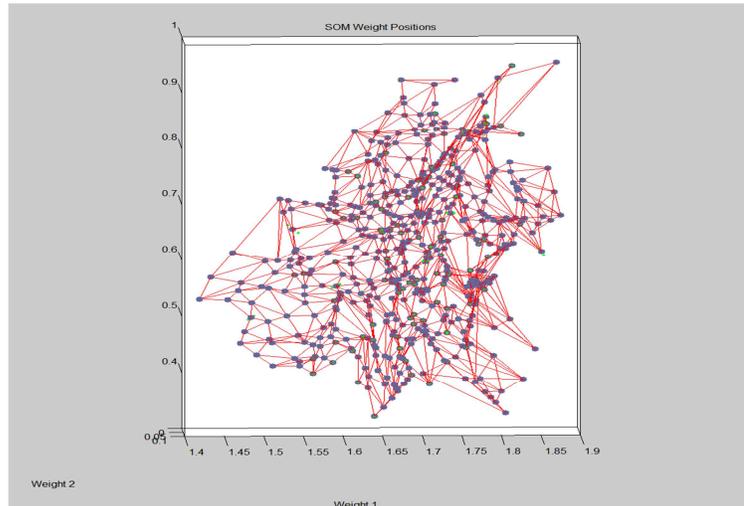
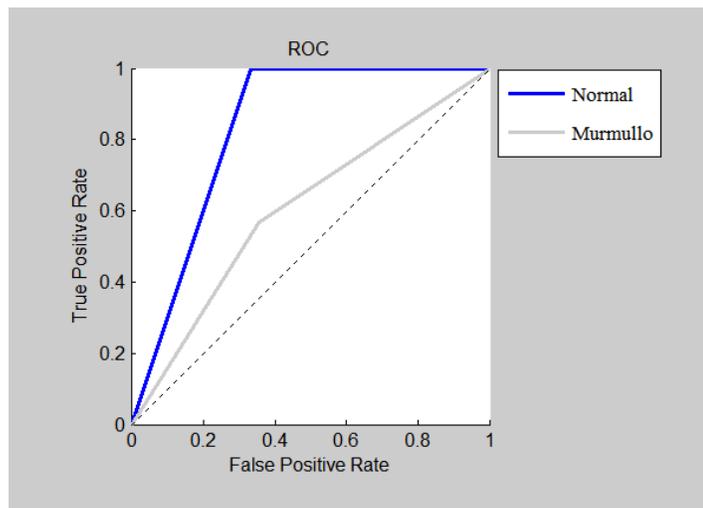


Fig. 11. Distribución de los pesos.



**Fig. 12. Posición de los pesos.**

A fin de mostrar el desempeño del clasificador, en la (Fig. 13) se presenta la gráfica Característica Operativa del Receptor (**ROC**), calculando el área bajo la curva (**AUC**). Se observa que para la clase normal se tiene un valor igual a 0.8334 el cual indica que la precisión en la clasificación es aceptable para esta clase, sin embargo, al obtener el segundo valor **AUC** se tiene un valor de 0.6053 que denota una precisión regular en la identificación de esta clase.



**Fig. 13. Característica Operativa del Receptor.**

## 4. Conclusiones

En este trabajo preliminar se han obtenido tres descriptores para la caracterización de dos clases de señales provenientes del corazón. La dimensión de correlación, el exponente de Lyapunov y la entropía aproximada fueron calculados para probar un sistema de clasificación basado en estas características.

Aunque los resultados muestran una segmentación en el entrenamiento de la red neuronal, la eficiencia en los resultados de clasificación demuestra que existen aún problemas de discriminación entre los descriptores que caracterizan las señales del corazón, por lo que el introducir y/o cambiar un descriptor podría mejorar la eficiencia y precisión en la clasificación. Así mismo, se abre la oportunidad de emplear esta técnica en aplicaciones en tiempo real para el reconocimiento de afecciones cardíacas, no solamente murmullo en fonocardiogramas.

## 5. Referencias

- [1] S. Schulz, K. Bär, A. Voss. Analyses of Heart Rate, “Respiration and Cardiorespiratory Coupling in Patients with Schizophrenia”. *Entropy*. Vol. 17. 2015. 483-501 pp..
- [2] C. Hoang, P. Stein, “Time frequency analysis of heart rate variability with chaos theory”. 13th International Conference on Computational Science and Its Applications. 2013. 174-177 pp.
- [3] B. Raghavendra. D. Dutt, “Multiscale fractal dimension technique for characterization and analysis of biomedical signals”. *Digital Signal Processing Workshop and IEEE Signal Processing Education Workshop (DSP/SPE)*. IEE. 2011. 370 – 374 pp.

- [4] N. Bhaskar, "Performance Analysis of Support Vector Machine and Neural Network in Detection of Myocardial Infarction". *Procedia Computer Science*. Vol. 46. 2015. 20-30 pp.
- [5] G. Redlarski, D. Gradolewski y A. Palkowski, "A System for Heart Sounds Classification". US National Library of Medicine National Institutes of Health. Ed. Alena Talkachova. 2014.
- [6] K. Balasubramanian, S. Nair y N. Nagaraj, "Classification of periodic, chaotic and random sequences using approximate entropy and Lempel-Ziv complexity measures". *Pramana, journal of physics*. Vol. 84. 2015. 365-372 pp.
- [7] D. Baoxiang, X. Wei, S. Bingbing, D. Qun y C. Shu-chuan, "Prediction of Chaotic Time Series of RBF Neural Network Based on Particle Swarm Optimization". *Intelligent Data Analysis and Its applications*. Vol. 2. 2014. 489-497 pp.
- [8] P. Grassberger y I. Procaccia, "Characterization of strange attractors". *Physical Review Lett*. Vol. 50. No. 346. 1983.
- [9] M. Rosenstein, J. Collins y C. Luca, "A practical method for calculating largest lyapunov exponents from small data sets". *Physica D*. Vol. 65. 1993. 117-34 pp.
- [10] M. Steven, Pincus y A. Goldberger, "Modelling in physiology. The american Physiological Society". *Cadiovascular Division*. No. 266. 1994.
- [11] The Pascal Classifying Heart Sounds Challenge. Disponible en: <http://www.peterjbentley.com/heartchallenge/index.html>. 2011.
- [12] P. O'Gara y J. Loscalzo, "Approach to the Patient with Heart Murmur". *Cardinal Manifestations and Presentation of Diseases*. 2012. McGraw-Hill. 13-10 pp.
- [13] T. Poari, H. Owaitha, "Heart and Lung Auscultation. CDHB Clinical Skills Unit. Canterbury". 2013. 1-30 pp.

- [14] H. Abarbanel, "Analysis of observed chaotic data". Springer-Verlag. 1995. 13-65 pp.
- [15] J. Sprott, "Chaos and Time-Series Analysis". 2003. Oxford University Press.
- [16] A. Casiano, H. González, "Automatic classification of EEG epileptic patterns using chaotic descriptors". Congreso Nacional de Control Automático. 2005.

## **6. Autores**

Ing. Carlos Antonio Osorio Maceda es Ingeniero en Tecnologías electrónicas con concentración en Robótica por el Tecnológico de Monterrey, Campus Puebla. Actual estudiante de la Maestría en Sistemas Inteligentes en la misma institución, sus intereses de investigación involucran análisis de bioseñales y reconocimiento de patrones.

Dr. Hugo G. González-Hernández obtuvo el grado de Doctor en Ciencias con especialidad en Mecatrónica por el CINVESTAV-IPN. Su trabajo de investigación se enfoca en el análisis y control de sistemas no lineales, robótica y visión artificial. Actualmente es profesor del Tecnológico de Monterrey, Campus Puebla.