Análisis no lineal de la dinámica intrínseca de las bioseñales con el fin de caracterizar patologias.

Carolina Ospina Aguirre

Universidad Nacional de Colombia
Facultad de Ingeniería y Arquitectura
Departamento de Ingeniería Eléctrica, Electrónica y Computación
Manizales, Colombia
2011

Análisis no lineal de la dinámica intrínseca de las bioseñales con el fin de caracterizar patologias.

Carolina Ospina Aguirre

Universidad Nacional de Colombia
Facultad de Ingeniería y Arquitectura
Departamento de Ingeniería Eléctrica, Electrónica y Computación
Manizales
2010

Análisis no lineal de la dinámica intrínseca de las bioseñales con el fin de caracterizar patologias.

Carolina Ospina Aguirre

Trabajo de grado como requisito parcial para optar al título de
Magíster en Ingeniería — Automatización Industrial

Director
Prof. César Germán Castellanos Domínguez

Grupo de Trabajo Académico Procesamiento y reconocimiento de Señales.

Universidad Nacional de Colombia
Facultad de Ingeniería y Arquitectura
Departamento de Ingeniería Eléctrica, Electrónica y Computación
Manizales
2010

Non linear analisys of the intrinsic dynamic of biosignals in order to characterize patologies

Carolina Ospina Aguirre

Thesis for the degree of
Master in Engineering — Industrial Automation

Supervisor
Prof. César Germán Castellanos Domínguez

Research group signal processing and recognition

National University of Colombia
Faculty of Engineering and Architecture
Department of Electrical, Electronic and Computing Engineering
Manizales
2011

Este trabajo fue financiado por el Programa de Becas para Estudiantes Sobresalientes de Posgrado y la Convocatoria Apoyo a Tesis de Posgrado - DIMA 2009 .

«Si dices basta, estás perdido.
Añade siempre, camina siempre,avanza siempre;
no te pares en el camino, no retrocedas, no te desvíes.
Se para el que no avanza;
retrocede el que vuelve a pensar en el punto de salida,
se desvía el que apostata.
Es mejor el cojo que anda por el camino
que el que corre fuera del camino».
«Examínate y no te contentes con lo que eres
si quieres llegar a lo que no eres.
Porque en el instante que te complazcas contigo mismo,
te habrás parado».
San Agustín

A la mujer que nunca ha parado de luchar.
Al hombre que nunca parará de soñar.
Alba Ledy Aguirre y Roberto Ospina.
Los Amo.

Agradecimientos

Agradezco en primer lugar a Dios que día a día guía mi camino, abre puertas y me fortalece en la debilidad trayendo a mi vida personas maravillosas.

Agradezco a mi madre, una guerrera incansable que con amor, paciencia y lucha diaria me ha motivado a levantarme cada mañana. A mi padre un soñador que cambió su historia haciéndo de lo "imposible" su realidad, motivándome así a ir más allá. A marga mi eterna compañera de batalla, mi alegría, mi sustento en los momentos difíciles. A Miguel un Ángel que llena nuestras vidas de esperanza y felicidad. Al Señor Diseñador por ser mi complemento, por hacerme sonrreir en todo momento por ser en mi vida como un oasis en el desierto. A la Señora Elisabeth y a su esposo Alfonso por su compañía desde la distancia, por sus palabras de aliento, sus oraciones y ayuda desmedida.
Agradezco a mis amigas Ana Cristina Cortes, Erika Marín Y Beatriz Elena Betancourth y a mis primas Angela Patiño y Adriana Buriticá por sus consejos y compañía aun en los momentos difíciles.

A Jorge Andrés Gómez por su colaboración en la elaboración de esta tesis. Al Profesor Edilson Delgado por su compañía, por todas sus enseñanzas dentro y fuera del aula de clase. Quiero agradecer a Johanna Carvajal por su amistad, por su paciencia, por todas sus correcciones, y consejos para mi vida académica y personal. Al Porfesor Germán Castellanos por su colaboración y dirección a lo largo del desarrollo de esta tesis y a los integrantes del Grupo de control y procesamiento Digital de Señales: Andrés Felipe Quinceno, Andrés Marino Alvares, Carolina Acosta, Diego Peluffo, David Cardenas, Genaro Daza, Juan David Martínez, Jorge Padilla, Juliana Valencia, Leonardo Duque, Lina María Sepúlveda, Luis David Avendaño, Oscar Cardona, Paola Castro y Santiago Murillo por todos sus aportes y discusiones académicas que me ayudaron en la elaboración de esta tesis y en especial por hacer más amenas las jornadas de trabajo.

Carolina Ospina Aguirre
Mayo de 2011.

Resumen

La metodología presentada en esta tesis está basada en una recopilación de métodos, herramientas y conceptos utilizados por el grupo de Control y Procesamiento Digital de Señales en el área del análisis de complejidad para la caracterización de señales biológicas tanto en los estados de normalidad como en los de anormalidad. Dicha metodología se desarrolla sobre señales fonocardiográficas, de voz y electroencefalográficas que contienen registros normales y patológicos, en primer lugar se realiza una caracterización mediante el uso de la dimensión de correlación, el exponente de Lyapunov y el exponente de Hurst, utilizando diferentes clasificadores: clasificador de la media más cercana, clasificador cuadrático, clasificador de los k vecinos más cercanos, clasificador de Fisher y maquinas de soporte vectorial con los cuales se evalúa el rendimiento de cada conjunto de características, el rendimiento máximo de clasificación que se obtiene para las señales analizadas es de 97.6%, 90.73% y 98.5% respectivamente. Además de la caracterización se realiza un análisis comparativo entre las características de complejidad de cada clase de los tres tipos de señales, con que se encuentran diferencias significativas entre los valores de dichas características que permiten diferenciarlas tanto en los estados de normalidad como en los patológicos. Los resultados obtenidos indican que la metodología desarrollada es efectiva y viable para la caracterización e identificación de patologías en bioseñales.

Palabras Clave: Técnicas de dinámica no lineal, FCG, ECG, Voz, Dimensión de correlación, Exponente de Hurst y Máximo Exponente de Lyapunov.

Abstract

The methodology presented is based on a collection of methods, tools and concepts used on the Group of Control and Digital Signal Processing into the complexity analysis area on characterization of Biological signals both normal and abnormality states. Such methodology is developed on phonocardiographic, voice and electroencephalografic signals containing normal and pathological records.

At first, the characterization employing relation dimension, Lyapunov exponent and Hurst exponent is done by using different classifiers: nearest mean classifier, quadratic classifier, k nearest neighbor classifier, Fisher classifier and support vector machines, which evaluate each features set performance. Maximum Performance Rate obtained for the analysed signals are 97.6%, 90.73% and 98.5% respectively. Besides characterization, comparative analysis among complexity characteristics of each class over all signals is performed and significant differences among values of such characteristics are found, which allows differentiating both normal and pathological states. Results indicate that the methodology described is effective for characterization and identification of pathologies on biosignals.

Keywords: Nonlinear Dynamics Techniques, PCG, ECG, Voice, Correlation dimension, Hurst Exponent and Lyapunov Exponent.

Contenido

Agradecimientos viii

Resumen ix

Abstract x

Lista de tablas xiii

Lista de figuras xiv

1. Preliminares 1
1.1. Planteamiento del problema 1
1.2. Antecedentes 2
1.3. Objetivos 2
1.3.1. General 2
1.3.2. Específicos 3

2. Marco teórico 4
2.1. Bioseñales 4
2.1.1. Señales Fonocardiográficas (FCG) 4
2.1.2. Señales de voz 6
2.1.3. Señales Electroencefalográficas (EEG) 8
2.2. Análisis no lineal 9
2.2.1. Espacio de fase 9
2.2.2. Parámetros de embebimiento 10
2.2.3. Medidas de Complejidad 12

3. Estado del arte 14

4. Marco experimental 17
4.1. Metodología 17
4.1.1. Señales Fonocardiográficas 17
4.1.2. Señales de voz 18
4.1.3. Señales Electroencefalográficas 18

5. Resultados 20
5.1. Señales de Voz 30
5.2. Señales Electroencefalográficas 33

6. Discusiones 39

7. Conclusión y trabajo futuro 41
7.1. Conclusiones 41

7.2. Trabajo futuro 41

Bibliografía 42

Lista de tablas

5.1	Porcentajes de precisión de clasificación para el segmento diastólico	20
5.2	Porcentajes de precisión de clasificación para los segmento Sistólico	23
5.3	Porcentajes de precisión de clasificación por característica para los segmentos del FCG analizados	25
5.4	Porcentajes de precisión de clasificación por parejas de características en señales FCG	27
5.5	Porcentajes de precisión de clasificación para las señales de FCG	27
5.6	Porcentajes de precisión de clasificación por característica en señales FCG	29
5.7	Porcentajes de precisión de clasificación por parejas de características en señales FCG	29
5.8	Porcentajes de precisión de clasificación para las señales de voz	30
5.9	Porcentajes de precisión de clasificación por característica en señales de voz	32
5.10	Porcentajes de precisión de clasificación por parejas de características en señales de voz	33
5.11	Porcentajes de precisión de clasificación para las señales EEG	34
5.12	Porcentajes de precisión de clasificación por característica en señales EEG	36
5.13	Porcentajes de precisión de clasificación por parejas de características en señales EEG	37

Lista de figuras

2.1	Fisiología del Corazón	5
2.2	Ciclo Cardíaco	6
2.3	Señal de voz normal	7
2.4	Aparato fonador y respiratorio	7
2.5	Electroencefalograma normal	8
2.6	Áreas del Cerebro	9
4.1	Diagrama de bloques del sistema de análisis de datos	17
5.1	Distribución de las características diastólicas normales y patológicas	20
5.2	Segmento diastólico	22
5.3	Distribución de las características sistólicas normales y patológicas	23
5.4	Segmento sistólico	24
5.5	Rendimiento del clasificador k-NN como función del número de vecinos	25
5.6	Distribución parejas de características segmento diastólico	26
5.7	Distribución parejas de características segmento sistólico	26
5.8	Distribución de las características en señales FCG normales y patológicas	27
5.9	Señales FCG	28
5.10	Distribución parejas de características en señales FCG	29
5.11	Distribución de las características en señales de voz normales y patológicas	30
5.12	Señales de voz	31
5.13	Rendimiento del clasificador k-NN como función del número de vecinos para señales de voz	32
5.14	Distribución parejas de características en señales de voz	33
5.15	Distribución de las características en señales EEG normales y patológicas	34
5.16	Rendimiento del clasificador k-NN como función del número de vecinos para señales EEG	35
5.17	Señales EEG	36
5.18	Distribución parejas de características en señales EEG	37
5.19	Diagrama de cajas de las diferentes señales	38

1. Preliminares

1.1. Planteamiento del problema

La medicina ha tenido un enorme desarrollo durante el presente siglo en gran parte debido a los avances tecnológicos del mundo científico. Un elemento fundamental en este desarrollo ha sido la intervención interdisciplinar en aplicaciones específicas para resolver los problemas clínicos. La unión de áreas como la matemática, y la biología ha permitido realizar investigaciones enfocadas a la modelización matemática de los sistemas fisiológicos y al desarrollo de teorías y de estructuras matemáticas más abstractas, con las cuales se pueden interpretar las observaciones sobre los sistemas, en especial los fisiológicos. La percepción profunda y las predicciones que surgen de una modelización matemática apuntan cada vez más hacia la toma de decisiones en medicina (inmunología, diseminación de enfermedades infecciosas, investigación en cáncer, investigación cardiovascular, investigación neurológica, optimización de tratamientos médicos, procesamiento de imágenes, etc) [Guillén et al., 2001].

La teoría de sistemas lineales ha permitido conocer los sistemas fisiológicos teniendo en cuenta que los procesos analizados son gobernados por el paradigma de que pequeñas causas llevan a pequeños efectos [Kantz and Schreiber, 2004]. Por otra parte, debido a que al modelar sistemas con ecuaciones lineales, sólo se pueden generar soluciones periódicamente oscilantes o de crecimiento exponencial; los comportamientos irregulares o aperiódicos, tradicionalmente, se atribuyen a influencias aleatorias externas como el ruido, o a interacciones entre un gran número de componentes constituyentes. Sin embargo, éstas no resultan ser las únicas fuentes de comportamiento irregular. Los sistemas dinámicos no lineales pueden producir este tipo de comportamientos con ecuaciones determinísticas, debido a pequeños cambios en parámetros de control y en variaciones en las condiciones iniciales, que pudieran explicar el comportamiento irregular observado en señales fisiológicas (bioseñales).

Estudios sobre bioseñales han demostrado su no linealidad [Nitish et al., 2004, Spasic et al., 2008] mediante la explicación del proceso fisiológico que las genera, por ejemplo en [Jiang et al., 2006] se muestra que en las señales de voz existe una relación no lineal entre la presión y el flujo de aire en la glotis, entre la deformación y la tensión de los tejidos de las cuerdas vocales y entre las cuerdas vocales producida por su colisión al formar los sonidos. Por otra parte, algunos estudios neurofisiológicos muestran que las señales EEG son altamente complejas [Diambra et al., 2001, Savi, 2005], esto se debe a que en el cerebro se presentan procesos de no linealidad incluso a nivel celular, ocasionados por la interacción entre las neuronas [Andrzejak et al., 2001].

En cuanto a las señales cardíacas, los intervalos entre latidos de un corazón humano sano muestran una fluctuación de forma compleja e irregular. Se presume, que dichas fluctuaciones son generadas por la existencia de comportamiento no lineal originado por el sistema nervioso, específicamente relacionado con las entradas neuroautónomicas. La estimulación del sistema parasimpático disminuye la actividad en el nodo sinusoidal del corazón, mientras que el sistema simpático la aumenta. El efecto de ambos estímulos genera una fluctuación en la tasa cardíaca que no puede ser explicada por el análisis lineal [Peng et al., 1995, Kikuchi et al., 2006].

Para resumir y describir los sistemas biológicos ha sido común el uso de técnicas lineales [?, Manrrique, 2009], sin embargo, esta descripción lineal no es suficiente, debido a que puede omitir información importante y relevante. Los sistemas biológicos se ajustan mejor al paradigma no lineal, porque todas sus variables deben ser tenidas en cuenta conjuntamente y no de manera aislada para generar la correspondiente salida [Dokoumetzidis et al., 2001]. Por tanto, parece coherente estudiar estos sistemas con los métodos de dinámica no lineal. En el contexto de detección de patologías, el análisis con dinámica no lineal ha generado un creciente interés debido a que se ha mostrado que cambios en medidas basadas en dinámica no lineal pueden indicar estados de disfunción patofisiológica [Jiang et al., 2006].

En este trabajo se presentará una metodología de análisis de bioseñales, a través de técnicas de dinámica no lineal como la dimensión de correlación, el exponente de Lyapunov y el exponente de Hurst con la cual se busca caracterizar las señales biológicas y realizar una separación entre la clase normal y la patológica en cada una de ellas. Mediante la caracterización también se pretende realizar una comparación entre las diferentes señales analizadas e identificar su dinámica de cambio según su origen y biológico y su estado de normalidad o anormalidad.

1.2. Antecedentes

En el Grupo de Control y Procesamiento Digital de Señales (GC&PDS) adscrito al Departamento de Ingeniería Eléctrica, Electrónica y Computación de la Universidad Nacional Sede Manizales y registrado ante Colciencias, se han desarrollado trabajos relacionados con los métodos de análisis no lineal en la detección de soplos cardíacos y en la caracterización de estados funcionales en fonocardiografía. También se han realizado trabajos enfocados en el procesamiento de bioseñales (reducción de perturbaciones, segmentación, caracterización y reconocimiento automático de señales ECG, reconocimiento de patologías de emisión vocal, etc.), e imágenes médicas (caracterización y reconocimiento de células cancerosas, caracterización biométrica de pacientes infantiles, etc) [Delgado, 2008].

1.3. Objetivos

1.3.1. General

- Identificar la dinámica de cambio de las bioseñales y realizar su comparación en tareas de identificación de patologías.

1.3.2. Específicos

- Identificar las restricciones en la estimación de las diferentes Características de Complejidad
- Ajustar las máquinas de estimación de diferentes características de análisis de complejidad a los cambios dinámicos locales de los registros de señales biológicas.

2. Marco teórico

2.1. Bioseñales

El cuerpo humano es un conjunto de multiples procesos químicos, electroquímicos, biológicos y fisiológicos. La actividad eléctrica, química o mecánica que ocurre durante eventos biológicos como el latido del corazón, la actividad cerebral y la producción de la voz frecuentemente produce señales que pueden ser medidas y analizadas [Morillo, 2008]. A continuación se describen las bioseñales utilizadas en este trabajo, su fisiología y una contextualización en el tipo de enfermedad analizada en cada una de ellas.

2.1.1. Señales Fonocardiográficas (FCG)

La señal fonocardiográfica corresponde a la adquisición de las vibraciones mecánicas provenientes del corazón y transmitidas por los tejidos vecinos hacia la pared torácica. En la creación de estos fenómenos acústicos participan los diferentes eventos mecánicos que se presentan durante el ciclo cardíaco, como son: la contracción muscular, la apertura y cierre de las válvulas y el desplazamiento del flujo sanguíneo. En el FCG se pueden observar los tiempos y las intensidades relativas de los sonidos cardíacos en forma clara y repetida. La fonocardiografía fue desarrollada para mejorar los resultados obtenidos con el estetoscopio convencional. El estado actual de la tecnología electrónica ha abierto nuevas posibilidades en el campo de la instrumentación para la auscultación de alta calidad, que incluye el desarrollo de sistemas digitales para la adquisición, registro, almacenamiento, y análisis de los sonidos cardíacos.

Descripción fisiologíca

El corazón tiene cuatro cámaras: dos cámaras superiores (aurículas) y dos cámaras inferiores (ventrículos). Además cuenta con cuatro válvulas que se cierran con cada latido cardíaco, haciendo que la sangre fluya en una sola dirección. Las válvulas localizadas entre las aurículas y los ventrículos son llamadas auriculoventriculares (AV)(Mitral y Tricúspide) y tienen la función de impedir que la sangre se regrese a las auriculas durante la sístole. Entre los ventrículos y los principales vasos del corazón se encuentran las válvulas sigmoideas(Pulmonar y Aórtica) que impiden que se regrese la sangre de las arterias aorta y pulmonar a los ventrículos durante la diástole [Ganong, 2006].

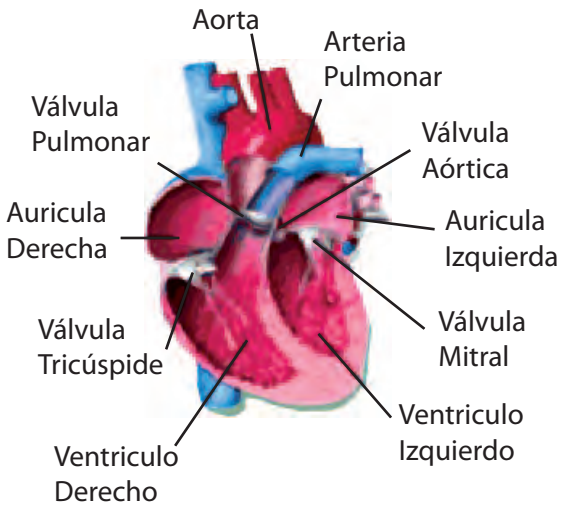

FIGURA 2.1. Fisiología del Corazón

Ciclo Cardíaco

Se define como ciclo cardíaco la secuencia de eventos eléctricos, mecánicos y sonoros que ocurren durante un latido cardíaco completo. Estos eventos incluyen la despolarización y repolarización del miocardio, la contracción (sístole) y la relajación (diástole) de las diferentes cavidades cardíacas, el cierre y apertura de válvulas asociado y la producción de ruidos concomitantes. Todo este proceso generalmente ocurre en menos de un segundo. De esta manera, la señal FCG está conformada por ciclos cardíacos sucesivos y generalmente cada ciclo puede dividirse en 4 partes: $S1$, sístole, $S2$ y diástole. Figura 2.2.

Primer sonido cardíaco $(S1)$. Es el generado por el cierre de las válvulas mitral (M) y tricúspide (T) en el inicio de la sístole ventricular [Durand and Pibarot, 1995].

Segundo sonido cardíaco $(S2)$. Ocurre en el fin de la sístole ventricular y el comienzo de la relajación ventricular, constituyendo dos componentes de alta frecuencia: cierre de las válvulas aórtica (A) y pulmonar (P), y apertura de las válvulas mitral (M) y tricúspide (T). El sonido $S2$ usualmente presenta componentes de más alta frecuencia que $S1$, y generalmente su duración es menor que la de S1.

Tercer y cuarto sonido ($S3$ **y** $S4$**)**. Ocasionalmente se escucha un tercer sonido cardíaco $S3$, que corresponde a la fase de llenado ventricular. Es una vibración acústica de baja frecuencia [Cheitlin and Skolow, 1993]. El cuarto sonido $S4$ es producido al final de la diástole, y se genera por la contracción de las aurículas desplazando el flujo sanguíneo hacia los ventrículos.

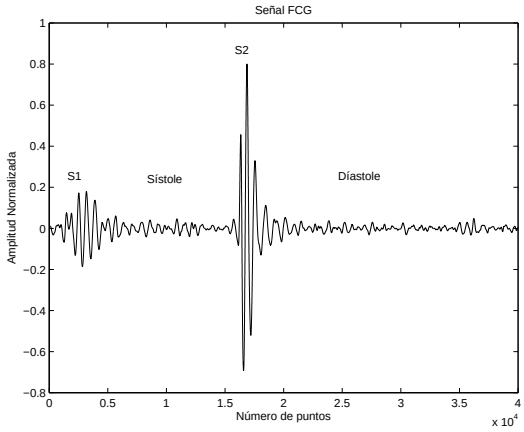

FIGURA 2.2. Ciclo Cardíaco

Fisiopatología

En circunstancias anormales, se pueden percibir sonidos sibilantes en los silencios del ciclo cardíaco los cuales son denominados soplos cardíacos. Los soplos pueden ser *funcionales* o *debidos a cardiopatias*. Los soplos funcionales son inofensivos, son comunes en los niños y no necesitan tratamiento, por lo general desaparecen al llegar a la edad adulta. En cambio, los soplos debidos a cardiopatias son síntoma de un problema cardíaco más importante, el silbido podría indicar que la sangre está fluyendo por una válvula cardíaca dañada, o que puede haber un orificio en las paredes del corazón, o un estrechamiento en alguno de los vasos sanguíneos. Los soplos, según el momento de aparición dentro del ciclo cardíaco, son llamados sistólicos (ocurren en la sístole),diastólicos ocurren en la diastole.

2.1.2. Señales de voz

La señal de voz es una señal acústica constituida por un conjunto de sonidos generados por el aparato fonador. Para su estudio es transformada en una señal eléctrica mediante micrófonos y representada en dos ejes cartesianos como se muestra en la Figura 2.3 que es la representación gráfica de una señal de voz correspondiente a la vocal $/a/$ pronunciada de forma sostenida.

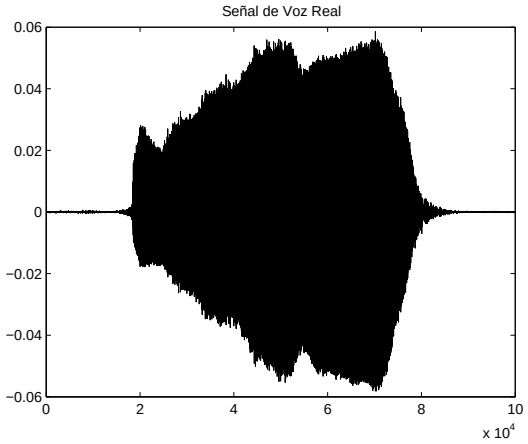

FIGURA 2.3. Señal de voz normal

Descripción fisiologíca

El aparato fonador humano es el conjunto de órganos que intervienen en la articulación del lenguaje en el ser humano. Está compuesto por tres grupos de órganos Figura 2.4:

(1) Órganos de respiración (Cavidades infraglóticas: pulmones, bronquios y tráquea).
(2) Órganos de fonación (Cavidades glóticas: laringe, cuerdas vocales y resonadores nasal, bucal y faríngeo)
(3) Órganos de articulación (cavidad supraglóticas: paladar, lengua, dientes, labios y glotis).

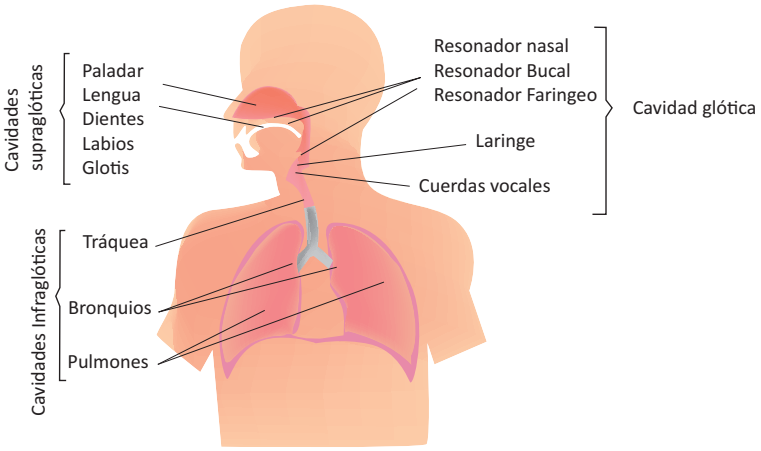

FIGURA 2.4. Aparato fonador y respiratorio

En el proceso de generación de la voz, el sonido inicialmente proviene de la vibración de las cuerdas vocales. Las cuerdas vocales son dos membranas ubicadas dentro de la laringe, la abertura entre ambas cuerdas se denomina glotis. Después de que el sonido atraviesa el glotis pasa a través de la cavidad supraglótica, en ella se modifica el sonido de acuerdo con la forma que adopten la lengua y los labios.

Fisiopatología

Habitualmente las alteraciones de las cuerdas vocales se producen por un mal uso de las mismas. Debido a uso excesivo de la voz al hablar, gritar, cantar, fumar, inhalar sustancias irritantes, toser, etc. Las patologías vocales más frecuentes son las disfonías funcionales (que no tienen causa orgánica aparente) y las mixtas, que son lesiones orgánicas de las cuerdas vocales, como nódulos, pólipos, granulomas y edemas. Además, se recibe un gran número de disfonías por inflamaciones laríngeas, debido a infecciones virales o bacterianas; por abuso vocal y como consecuencia de irritantes como el reflujo gastroesofágico [Cobeta and Tapia, 1996].

2.1.3. Señales Electroencefalográficas (EEG)

La electroencefalografía es un estudio de la función cerebral que recoge la actividad eléctrica de las neuronas en situación basal de reposo, vigilia o sueño y se utiliza para detectar anomalías en dicha actividad. El EEG realiza un seguimiento de las ondas cerebrales y es adquirido mediante electrodos que son colocados sobre el cuero cabelludo, estos electrodos envían señales a una computadora para registrar los resultados. Por medio de las señales electroencefalográficas los médicos pueden buscar patrones anormales que indiquen convulsiones, ataques epilépticos u otros problemas [Contreras-Troya et al., 2009]. En la Figura 2.5 se muestra una señal electrocardiográfica normal.

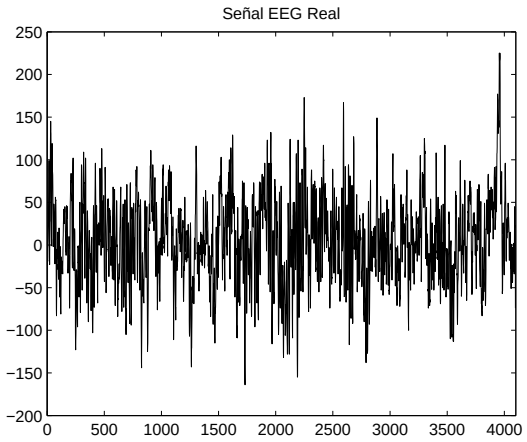

FIGURA 2.5. Electroencefalograma normal

Descripción fisiologíca

El cerebro es un órgano altamente complejo ya que está compuesto de millones de células llamadas neuronas, en él, se encuentra el centro del sistema nervioso humano. El cerebro normal genera constantemente estímulos eléctricos que son transmitidos de neurona a neurona a través de los axones , y funciones como la vision, el pensamiento y el movimiento muscular dependen de estos estímulos nerviosos. El cerebro humano está divido por dos hemisferios (Derecho e Izquierdo), cada hemisferio está subdividido en lóbulos como se muestra en la Figura 2.6. [Rouviere, 2001].

- Lóbulo frontal: Es el encargado de los movimientos voluntarios, del razonamiento, de la solución de problemas y de una parte del lenguaje y las emociones.
- Lóbulo Temporal: Está encargado de la audición, equilibrio y coordinación, regula emociones y motivaciones como ansiedad, placer e ira.
- Lóbulo Parietal: Es el encargado del area sensorial externa relacionada a la percepción de los sentidos, sensibilidad , presión, temperatura y dolor.
- Lóbulo occipital: Encargado del area visual y creación de imágenes.

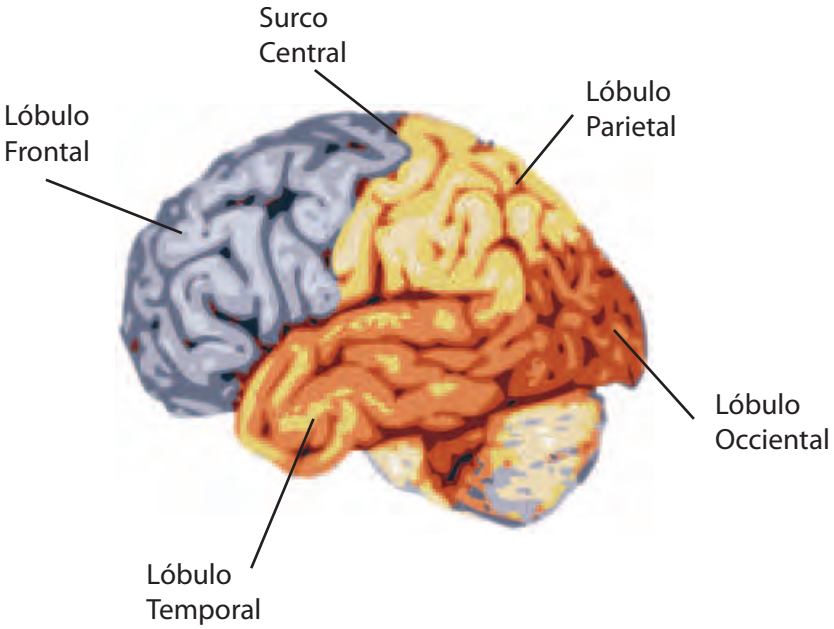

FIGURA 2.6. Áreas del Cerebro

Fisiopatología

La epilepsia es un desorden que inicia en el cerebro, se produce por una descarga eléctrica anormal en una zona específica del cerebro, conocida como foco epiléptico, generando una interrupción en el normal desarrollo de las funciones cerebrales; no es una enfermedad, sino el síntoma de una alteración neurológica que afecta al cerebro y se manifiesta en forma de crisis [Contreras-Troya et al., 2006, Contreras-Troya, 2007].

2.2. Análisis no lineal

A continuación se hace una breve descripción de los conceptos básicos para el análisis no lineal, además y de las medidas de complejidad que serán utilizadas a lo largo de este trabajo, para analizar las bioseñales.

2.2.1. Espacio de fase

Los sistemas dinámicos no lineales son aquellos cuya respuesta ante un estímulo dado en algún instante de tiempo no se produce de forma proporcional a su respectiva excitación de entrada [Kantz and Schreiber, 2004]. En ciertas circunstancias, los sistemas determinísticos no lineales, entran en un estado llamado caos, cuando la respuesta del sistema presenta una

notable sensibilidad a las condiciones iniciales del modelo; es por esto, que aunque exista un modelo determinístico del sistema no lineal, al entrar en el régimen caótico, se genera un comportamiento impredecible a largo plazo, si no se tienen de manera precisa las condiciones iniciales [Parker and Chua, 1987].

El análisis de los sistemas dinámicos se realiza mediante el uso de ecuaciones diferenciales parciales, como modelos matemáticos [Cross and Hohenberg, 1993, Gollub and Langer, 1999]. Un sistema dinámico puede ser expresado matemáticamente por un conjunto de ecuaciones diferenciales no lineales de la forma:

$$\dot{x} = fx(t) \tag{1}$$

Donde f es una función vectorial no lineal que representa las reglas dinámicas que gobiernan el comportamiento de las variables, y $\mathbf{x}(t) = [x_1(t), ..., x_l(t)]$ es el vector de estado de dimension $l \times 1$ que representa las variables dinámicas del sistema. La solución de la Ecuación (1) corresponde a una trayectoria u órbita en un espacio multidimensional conocido como *espacio de estados* o *espacio de fase*, el cual es un espacio vectorial abstracto generado por las variables dinámicas del sistema que representan la evolución en el tiempo. Si adicionalmente los sistemas son disipativos, habrá una atracción a un subconjunto del espacio de estados, que recibirá el nombre de atractor del sistema [Kantz and Schreiber, 2004].

Una serie de tiempo escalar, $s(t)$, puede ser utilizada para construir un vector de estados que es topológicamente equivalente al de la dinámica original. La técnica más conocida de reconstrucción de espacios de fase para sistemas dinámicos discretos es el *método por tempos de retardos* [Savi, 2005]. El cual consiste en usar variables de tiempos anteriores $s(t + \tau)$, donde τ es el tiempo de retardo y $t = t_0 + (n - 1)\Delta t$ con $n = 1, 2, 3, ..., N$, es posible usar una colección de retardos de tiempo para crear un vector en un espacio m - dimensional, $\mathbf{u}(t)$, el cual representa la dinámica del sistema reconstruido.

$$\mathbf{u}(t) = \{s(t), s\,(t + \tau)\,, ..., s\,(t + (m - 1)\,\tau)\}^T \tag{2}$$

Donde m es la dimensión de embebimiento o el mínimo número de coordenadas para representar la señal sin que se presenten traslapes en el espacio de estados.

Según el teorema de Takens para reconstruir una serie de tiempo, tal que las propiedades del atractor original sean topológicamente equivalentes a la reconstrucción formada por vectores de fase m-dimensionales, se debe cumplir que $m \geq 2d + 1$,siendo d la dimension del espacio de representación del sistema dinámico.

2.2.2. Parámetros de embebimiento

Se conoce como parámetros de embebimiento a la dimensión de embebimiento m y el tiempo de retardo τ , el ajuste adecuado de estos parámetros es información obligatoria para obtener la reconstrucción del espacio de estados, o de embebimiento, a partir de una serie de tiempo [Takens, 1981, Sauer et al., 1991].

Cálculo del tiempo de Retardo (τ)

El tiempo de retardo es un parámetro de libre elección, sin embargo un τ apropiado facilita el análisis de los sistemas no lineales. Un tiempo de retardo pequeño genera vectores de estado fuertemente correlacionados y uno grande genera vectores de estado casi independientes, dispersos sobre todo el espacio de fases [Kantz and Schreiber, 2004]. Uno

de los principales métodos para estimar el valor del tiempo de retardo τ es el cálculo de la *información mutua promedio* (AMI) de la series de tiempo analizadas $s(t)$ y $s(t+\tau)$:

$$I(\tau) = \sum \Gamma_b\left(s(t), s(t+\tau)\right) \log_2 \left[\frac{\Gamma_b\left(s(t), s(t+\tau)\right)}{\Gamma_b\left(s(t)\right)\Gamma_b\left(s(t+\tau)\right)}\right] \tag{3}$$

donde $\Gamma_b\left(s(t), s(t+\tau)\right)$ es la densidad de probabilidad conjunta para $s(t)$ y $s(t+\tau)$, así como $\Gamma_b\left(s(t)\right)$ y $\Gamma_b\left(s(t+\tau)\right)$ son las densidades de probabilidad marginales para $s(t)$ y $s(t+\tau)$ respectivamente. Con una mayor independencia estadística entre las series de análisis, se espera que la cantidad de información entre las medidas, es decir, la información mutua, sea igual a cero. Esta es una idea teórica que conecta dos conjuntos de medidas, una con respecto a otra, estableciendo un criterio para su dependencia mutua basada en la noción de conexión de información entre ellas. Sin embargo, para valores suficientemente grandes de τ las series $s(t)$ y $s(t+\tau)$ pueden considerarse independientes, e $I(\tau)$ tenderá a cero. El valor de τ se toma entonces donde se presenta el primer mínimo de la información mutua promedio $I(\tau)$ como valor para emplear en la reconstrucción del espacio de fase [Abarbanel, 1996, Baker and Gollub, 1990]. El procedimiento para escoger el primer mínimo de la información mutua promedio es similar al que se utiliza para escoger el primer cero de la función de autocorrelación lineal:

$$C(\tau) = \sum_t (s(t) - \bar{s})(s(t+\tau) - \bar{s}) \tag{4}$$

donde $\bar{s} = \frac{1}{N}\sum_{t=1}^{N} s(t)$, es el tiempo en el cual se escoge el retardo τ.

Para cierto τ lo suficientemente grande la probabilidad conjunta será igual al producto de las distribuciones separadas (marginales) y la información mutua será cero.

Calculo de la dimensión de Embebimiento (m)

A pesar de que el teorema de Takens asegura la construcción de un espacio de fases difeomorfo al espacio de fases original para una dimensión de embebimiento m suficientemente grande, la elección de dicha dimensión debe de realizarse con cuidado cuando se dispone de una serie temporal finita cuyos datos, además, pueden estar afectados por ruido [Delgado-Trejos et al., 2009]. Aunque cualquier valor mayor al m óptimo es aceptable, se debe tener cuidado ya que un m muy grande agregará coordenadas redundantes en el espacio de estados. La estimación del parámetro m comúnmente se realiza utilizando el método de los falsos vecinos (False Neares Neighbors - FNN), el cual consiste en realizar una búsqueda de puntos que sean vecinos en el espacio de estados, pero que no deberían serlo porque tienen una evolución temporal diferente [Kantz and Schreiber, 2004].

Este método considera un espacio m-dimensional donde el punto $\mathbf{u}(t)$ tiene r vecinos cercanos, $\mathbf{u}^{(r)}(t)$. EL cuadrado de la distancia euclídea entre estos puntos es:

$$r_D^2(t, r) = \sum_{k=0}^{D-1} \left[s(t+k\tau) - s^{(r)}(t+k\tau)\right]^2 \tag{5}$$

Ahora, al pasar de una dimensión m a $m+1$ por un intervalo de tiempo, hay un nuevo sistema coordenado, y como consecuencia, una nueva distancia entre $\mathbf{u}(t)$ y $\mathbf{u}^{(r)}(t)$. Cuando

estas distancias se modifican de una dimensión a otra, existe un falso vecino, cuando la cantidad de falsos vecinos es cero cuando se tiene la dimension m apropiada.
Un criterio natural para detectar errores en la dimension de embebimiento es que el incremento de la distancia entre $\mathbf{u}(t)$ y $\mathbf{u}^{(r)}(t)$ sea grande al pasar de una dimensión m a $m+1$. [Savi, 2005].

2.2.3. Medidas de Complejidad

Dimension de Correlación (D_2) La dimensión de correlación es uno de los parámetros utilizados para describir atractores. Básicamente proporciona una métrica de la complejidad del sistema en relación al número de grados de libertad del mismo. Grassberg y Procaccia [Grassberger and Procaccia, 1983] propusieron un método para determinar D_2 de forma experimental. El método está basado en que: la probabilidad de que dos puntos del conjunto estén en la misma esfera de radio r es aproximadamente igual a la probabilidad de que dos puntos del conjunto estén separados por una distancia ρ menor o igual a r [Henry et al., 2000]. De modo que la dimensión de correlación puede ser escrita como:

$$D_2 = \lim_{r \to 0} \frac{\log C(r)}{\log r} \tag{6}$$

donde la suma de correlación $C(r)$ está dada aproximadamente por:

$$C(r) \approx \frac{\sum_{i=1, j>i}^{N} \Theta\left(r - \rho(\mathbf{u}_i, \mathbf{u}_j)\right)}{\frac{1}{2}N(N-1)} \tag{7}$$

La función de Heaviside es definida como:

$$\Theta(s) = \begin{cases} 1 & si \quad s \geq 0 \\ 0 & si \quad s < 0 \end{cases} \tag{8}$$

La aproximación en la Ecuación (7) es exacta en el límite $N \to \infty$. Debido a que los límites $N \to \infty$ y $r \to 0$ de la Ecuación (6) no son realizables físicamente, Grassberg y Procaccia propusieron la evaluación de $C(r)$ sobre un rango de valores de r para inferir D_2 de la pendiente de la línea recta de mejor ajuste en la region escalar lineal de la gráfica entre $\log C(r)$ y $\log r$.

La distancia euclídea es la más utilizada para medir ρ en (7):

$$\rho(\mathbf{u}_i \mathbf{u}_j) = \sqrt{\sum_{k=1}^{m} \left(u_i(k) - u_j(k)\right)^2} \tag{9}$$

Exponente Hurst (H) El exponente de Hurst es un número que indica el grado de influencia del presente sobre el futuro (grado de similitud del fenómeno con el "Movimiento Browniano" o "Camino Aleatorio"). Se calcula para detectar situaciones de memoria a largo plazo en una serie de tiempo. [Pallikari and Boller, 1999]. El valor de este exponente varía entre 0 y 1. Cuando $H > 0.5$, se dice que el sistema es persistente (correlación positiva), es decir, las tendencias del pasado permanecerán en el futuro. Cuando $H = 0.5$ el sistema es aleatorio(correlación nula) comportamiento similar al ruido blanco Gaussiano. Finalmente

si $H < 0.5$ se habla de un sistema antipersistente (correlación negativa), en el que las tendencias del pasado serán inversas en el futuro.

Para calcular el exponente de Hurst se utiliza el método de escalamiento en el rango R/S . En este método, se transforma la señal $s(t)$ en una nueva variable $S(t, N)$ mediante la siguiente transformación:

$$S(t, N) = \sum_{i=1}^{t} (s_i - \bar{s}_N) \tag{10}$$

donde s_i es la señal y $\bar{s}_N$ es la media de la señal.

Luego se calcula el cociente entre el rango $R(N)$ (11) y la desviación estándar de las observaciones $S(N)$ (12).

$$R(N) = \max(S(t, N)) - \min(S(t, N)) \tag{11}$$

Donde el rango $R(N)$ es la distancia entre el mínimo y el máximo valor de S

$$S(N) = \left\{ \frac{1}{N} \sum_{t=1}^{N} [s_t - \bar{s}_N]^2 \right\}^{1/2} \tag{12}$$

El valor de H se define como la pendiente que se obtiene al calcular la media de la relación R(N)/S(N), para diferentes escalas en la longitud de los datos de la serie de tiempo analizada.

Exponente Lyapunov (λ) EL exponente de Lyapunov mide la divergencia (o convergencia) de órbitas cercanas en el espacio de fases. Representan, por lo tanto, uno de los atributos básicos del caos determinista: la sensibilidad a las condiciones iniciales. En un sistema dinámico hay tantos exponentes como dimensiones en el espacio de fase, sin embargo el Máximo Exponente de Lyapunov (Lyapunov Largerst Exponent - LLE), es el más importante [Kantz and Schreiber, 2004]. Un exponente negativo significa una aproximación de las trayectorias en la misma dirección, es decir, la señal sería convergente tendiendo a un punto fijo y, si el exponente fuese positivo, la divergencia se agrandaría, evidenciando conducta caótica. Así, los exponentes negativos comprimen el sistema, mientras que los positivos lo expanden.

Sean $\mathbf{S_{n1}}$ y $\mathbf{S_{n2}}$ dos puntos en el espacio de estados con distancia $\|\mathbf{S}_{n1} - \mathbf{S}_{n2}\| = \delta_0 \gg 1$. Y sea $\delta_{\Delta n}$ la distancia un tiempo después Δn, entre dos trayectorias emergiendo de esos puntos,$\delta_{\Delta n} = \|\mathbf{S}_{n1+\Delta n} - \mathbf{S}_{n2+\Delta n}\|$. Entonces LLE es determinado por

$$\delta_{\Delta n} \simeq \delta_0 e^{\lambda \Delta n}, \quad \delta_{\Delta n} \ll 1 \quad \Delta n \gg 1$$

$$\lambda(\delta_0) = \lim_{\Delta n \to \infty} \lim_{\|\delta_0 \to 0\|} \frac{1}{\Delta n} \log \frac{\|\delta_{\Delta n}\|}{\|\delta_0\|} \tag{13}$$

Si el valor de LLE es positivo existe una divergencia exponencial entre trayectorias cercanas, es decir, existe caos. Si es negativo refleja la existencia de atractores con puntos fijos estables. Cuando LLE es cero existen ciclos límites estables, y valores infinitos sugiere señales ruidosas.

3. Estado del arte

Los sistemas dinámicos no lineales son estudiados a través de las técnicas de análisis de complejidad ya que han demostrado ser útiles en una amplia variedad de aplicaciones físicas, ecológicas, químicas, económicas y actualmente en ciertos procesos fisiológicos [Rondón, 2002].

El análisis de complejidad provee información intrínseca del sistema dinámico, es por esto se utiliza en diferentes campos. En el de la física por ejemplo, el uso de características como la dimensión de correlación, ha sido exitoso en tareas como: la detección y diagnóstico de fallas [Ghafari et al., 2008, Logan and Mathew, 1996, Hou and Li, 2010, Wang et al., 2001] y en la la identificación de condiciones normales y su diferenciación de las anormales [Jiang and Chen, 1999]. En el financiero, se utiliza el exponente de Hurst (H) como indicador de la influencia de las tendencias pasadas sobre el futuro en los en los diversos mercados [Peters, 1989, Peters, 1992, Mansilla, 2003], y en los activos financieros [Holyst and Zebrowska, 2000].

Dentro de los procesos fisiológicos el análisis de las señales es de particular interés debido a su aplicación en el diagnóstico clínico, se han utilizado las características de complejidad como el exponente de Lyapunov (λ), la dimensión de correlación (D_2) y el exponente de Hurst H, para describir y caracterizar bioseñales (Electrocardiográficas (ECG), Fonocardiográficas(FCG), Electroencefalográficas (EEG) y señales de voz) [Casaleggio et al., 1990, Cerquera, 2005, Guillén et al., 2001, Carvajal et al., 2002, Delgado et al., 2009]. El exponente de Lyapunov, por ejemplo ha sido utilizado para describir algunos aspectos del control de mecanismos en la fisiología humana [Pradhan et al., 1995] inclusive para analizar el flujo de sangre periférico [Bracic and Stefanoska, 1998].

Dado que al analizar la variabilidad de la frecuencia cardíaca (HRV-Heart rate variability) se observan complejidades que no son lineales, en [Avila, 2003] se trata el HRV como un sistema no lineal para obtener información sobre su dinámica, en [Berraondo et al., 2001, Carvajal et al., 2002] es estudiado en cuanto a la existencia de determinismo no lineal en el comportamiento eléctrico del corazón. [Carvajal et al., 2005], por su parte calcula la dimensión de correlación al HRV de un grupo de pacientes con una miocardiopatía dilatada (DCM - dilated cardiomyopathy) y a un grupo de sujetos sanos. Los resultados obtenidos muestran que el valor de la D_2 para pacientes con DCM es significativamente más pequeña que en los sujetos sanos.
[Voss et al., 1996] presenta una comparación entre las características dinámicas de personas saludables, y personas con alto riesgo de muerte cardíaca súbita, evidenciando la relación existente entre la respuesta caótica de las señales cardíacas y las arritmias.

En [Rodríguez et al., 2008] se presenta una metodología de análisis dinámico para la identificación de patologías, basada en los atributos no lineales de las bioseñales. Proponen medidas de complejidad tales como el máximo exponente de Lyapunov, el exponente de Hurst y la dimensión de correlación para caracterizar su estructura dinámica y el uso de registros MER (microelectrodos de registro) y ECG (electrocardiogramas) para validar las técnicas propuestas. La información conjunta para cada uno de los grupos de señales muestra un desempeño del 91,51 $\%$ de acierto; así las técnicas de dinámica no lineal toman en cuenta la dinámica intrínseca y estructura de la señal para discriminar sus respectivas patologías.
El estudio de la presencia de comportamiento no lineal en señales FCG sugiere la utilidad del análisis de complejidad basado en dinámica no lineal, como se presenta en [Nigam and Priemer, 2005]. Caracterizaciones basadas en estadísticas de alto orden, teoría del caos y complejidad fractal han sido propuestas para describir el comportamiento dinámico de las señales FCG [Ahlstrom et al., 2006]. En [Delgado et al., 2009] se realiza una comparación entre características espectrales y fractales para la detección de soplos, mostrando la mayor capacidad discriminante de las características basadas en dinámica no lineal.

Para la caracterización de señales de voz se ha utilizado el exponente de Lyapunov [Banbrook et al., 1999, Pitsikalis et al., 2003], y la dimension de correlación ya que es estadísticamente mayor en las señales patológicas que en las normales [Zhang et al., 2005]. El trabajo realizado por [Jiang and Zhang, 2002] muestra la baja dimensionalidad de las características dinámicas tanto en las voces normales como en las patológicas. El análisis realizado con la dimensión de correlación refleja diferencias estadísticas significantes entre los dos grupos analizados,las cuales permiten utilizar la D_2 como una herramienta útil para la clasificación entre las clases normal y patológica en señales de voz [Zhang and Jiang, 2003].

Se han realizado estudios en el análisis de EEG para caracterizar estados neurofisiológicos, observándose estructuras fractales en los registros de electroencefalogramas [Chen and Yau, 1998, Contreras-Troya, 2007, Morillo,]. El análisis de complejidad se ha utilizado para medir la dinámica cerebral [Faure and Korn, 2003, Korn and Faure, 2003], y en algunos casos, para estudiar pacientes con epilepsia. En [Sackellares et al., 1999] se encontró que la epilepsia del lóbulo temporal está caracterizada por episodios de descargas eléctricas (actividad ictal), las cuales consisten en una actividad sincronizada de las neuronas temporales, particularmente las del hipocampo. Los autores sostienen que el cerebro epiléptico es un sistema caótico no lineal, el cual repetidamente hace transiciones dentro y fuera del estado ictal porque el foco epileptogénico lo lleva a un estado autorganizado del caos al orden. Cuando el caos espacio-temporal en el cerebro falla, las convulsiones representan un mecanismo del cerebro para retornar su dinámica a un estado más normal (caótico). Así, las convulsiones sirven como mecanismo restaurador orden-caos. [Contreras-Troya et al., 2009] determinó el exponente de Hurst para analizar series de tiempo de EEG de personas que no tienen epilepsia, pero que han tenido algún problema neurológico, y de personas que la padecen, con la finalidad de hacer una comparación entre ellos. En este estudio se encontraron fluctuaciones significativas en el valor del exponente de Hurst cuando se presentan

cambios repentinos en la actividad cerebral, lo cual refuerza la idea de que este exponente permite la detección de ataques epilépticos.

4. Marco experimental

4.1. Metodología

La metodología desarrollada en este trabajo se compone de 3 partes principales: preprocesamiento, caracterización, clasificación (ver Figura 4.1).

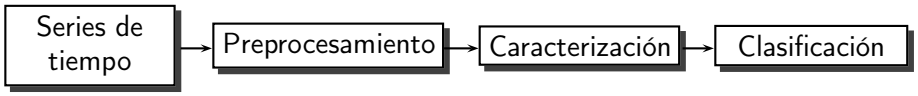

FIGURA 4.1. Diagrama de bloques del sistema de análisis de datos

El preprocesamiento consta de dos partes, la primera es la centralización y la segunda consiste en la normalización de amplitud, para que el rango dinámico de las señales se mantenga constante, independientemente de la señal que se esté analizando.
La etapa de caracterización consiste en la estimación de las características de complejidad (Dimensión de correlación, exponente de Lyapunov y exponente de Hurst), que posteriormente serán normalizadas entre cero y uno.

Para el proceso de clasificación se utilizó Cross-validación 10 fold y el conjunto de características se dividió en 70% para entrenamiento y el 30% restante para validación. Se realizaron pruebas con diferentes clasificadores: Clasificador de la media más cercana (NM), clasificador cuadrático (QD), clasificador de los k vecinos más cercanos (KNN), clasificador de Fisher (F) y máquinas de vectores de soporte (SV), para analizar cuál de ellos ofrece mejores porcentajes de precisión de clasificación, en cada tipo de señal.

4.1.1. Señales Fonocardiográficas

Base de Datos

La base de datos usada en este estudio consta de 45 sujetos adultos, quienes dieron su consentimiento informado aprobado por un comité ético y se sometieron a un examen médico. El diagnóstico se llevó a cabo para cada paciente, y la severidad de la afección valvular fue evaluada por cardiólogos de acuerdo con los procedimientos rutinarios. Un conjunto de 26 pacientes fue etiquetado como normal, mientras que 19 mostraron evidencia de soplos sistólicos y soplos diastólicos, causados por deficiencias valvulares. Además, para cada paciente, se tomaron 8 registros correspondientes a los cuatro focos tradicionales de auscultación (mitral, tricúspide, aórtico y pulmonar) en las fases de apnea post-espiratoria y postinspiratoria. Cada registro tiene una duración aproximada de 12s y se obtuvo con el paciente en la posición de decúbito dorsal. El tiempo de grabación de cada registro no se

puede extender más, pues los pacientes que sufren de problemas cardíacos son incapaces de mantener la apnea post-espiratoria y post-inspiratoria por un tiempo mayor. Luego de una inspección visual y auditiva llevada a cabo por especialistas cardiólogos, se etiquetaron los datos por cada latido del paciente y se tomaron los mejores latidos de la base de datos, la cual quedó conformada por 274 latidos normales e igual cantidad de latidos patológicos con el fin de tener las clases balanceadas en cuanto al número de observaciones por cada clase. Se decide realizar un diagnóstico por cada uno de los latidos, pues los soplos cardíacos generalmente no aparecen en todos los focos de auscultación a menos que sean muy intensos, y es más precisa la evaluación por cada uno de los latidos en vez de tener en cuenta el registro completo del paciente. Las señales se adquirieron con un estetoscopio electrónico (modelo WelchAllyn R Meditron), con el cual se graba simultáneamente la señal FCG y una derivación de la señal electrocardiográfica (ECG) (DII), la cual se utiliza como referencia de sincronización para segmentar cada uno de los latidos. Ambas señales se muestrean a una tasa de 44,1kHz con una precisión de 16 bits. Esta base de datos pertenece al grupo de Control y Procesamiento Digital de Señales de la Universidad Nacional de Colombia, Sede Manizales.

El preprocesamiento aplicado a este tipo de señales consiste en primer lugar en realizar un remuestreo a $4000hz$ según lo sugerido por [Manrrique et al., 2009], después se realiza una centralización y normalización de la señal. La segmentación para las señales FCG se lleva a cabo con la metodología presentada en [Delgado et al., 2009],que permite extraer los segmentos sístole y diástole de la señal y así proceder a caracterizarlos.

4.1.2. Señales de voz

Base de Datos

Esta base de datos fue desarrollada por el Massachusetts Eye and Ear Infirmary Voice Laboratory (MEEIVL) [Eye and E.I.L.MEEIVL, 1994]. Los registros corresponden a pronunciaciones de la vocal sostenida /ah/. Se utilizaron 173 registros de pacientes patológicos (con una amplia gama de patologías vocales: orgánicas, neurológicas, traumáticas y psíquicas) y 53 registros de pacientes normales, tomadas en un cuarto a prueba de sonido, a una frecuencia de muestreo de $44.1kHz$ y 16 bits de resolución [Parsa and Jamieson, 2000].

Adicional a la centralización y normalización en la etapa de preprocesamiento fue necesario remuestrear los registros a $25Khz$ debido a la heterogeneidad de la base de datos (diferente frecuencia de muestreo en la adquisición de los registros). Se empleó un análisis de tiempo corto, con ventanas cuadradas de $55ms$ de duración y 50% de traslape.

4.1.3. Señales Electroencefalográficas

Base de Datos

Los datos utilizados para las pruebas fueron recolectados por La Clínica para Epilepsia de la Universidad de Bonn [Andrzejak et al., 2006]. La base de datos consta de cinco conjuntos (denotados A-E) compuestos por 100 segmentos de EEG de un canal. Los conjuntos A y B consisten de segmentos tomados de registros EEG superficiales (cuero cabelludo) en cinco personas saludables usando el esquema estándar de localización de electrodos 10–20. Los voluntarios se encontraban relajados en estado de vigilia con los ojos abiertos (A) y los

ojos cerrados (B), respectivamente. Los conjuntos C, D y E se originan de registros EEG de diagnóstico prequirúrgico. Los segmentos en el conjunto D fueron registrados dentro de la zona epileptopatogénica, y los del conjunto C de la formación hipocampal del hemisferio opuesto del cerebro. Mientras que los conjuntos C y D contienen solamente actividad medida durante los intervalos interictales, el conjunto E contiene solamente actividad ictal. Todas las señales EEG fueron registradas con un sistema de adquisición de 128 canales, utilizando una referencia común promediada. Los datos fueron digitalizados a $173.61\ Hz$ con una resolución de $12\ bits$.

A las señales EEG adicional a la etapa de preprocesamiento mencionado es necesario aplicarles un filtro pasa bajas, esto es debido a que las bandas frecuenciales de interés clínico(delta $(0.5 - 3.5)Hz$, theta $(3.5 - 7.5)Hz$, alfa $(7.5 - 13)Hz$ y beta $(13 - 35)Hz$) son de baja frecuencia [Rowan and Tolunsky, 2004].

5. Resultados

Señales Fonocardiográficas

A continuación se presentan los resultados obtenidos al caracterizar cada uno de los segmentos de las señales FCG.

Segmento Diastólico

La Figura 5.1 muestran la distribución de las características calculadas sobre el segmento diástole. En azul las características de la clase normal y en verde las de la patológica. Se puede notar la separabilidad entre las clases normal y patológica, esto se sustenta con los altos valores de los porcentajes de precisión de clasificación (ver Tabla 5.1).

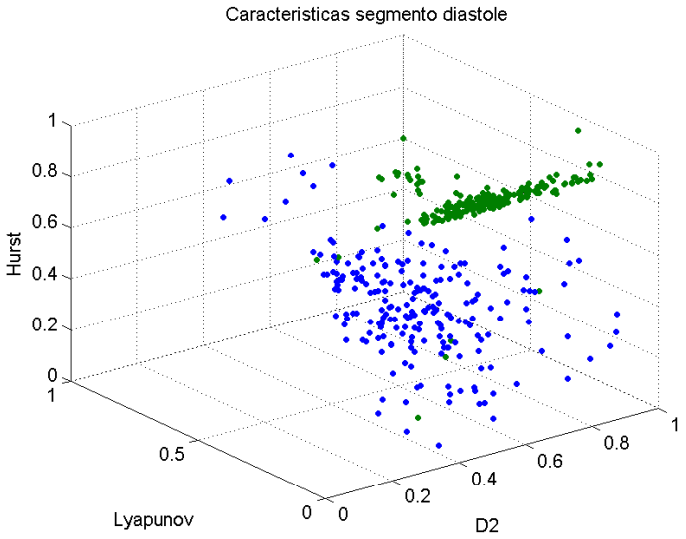

FIGURA 5.1. Distribución de las características diastólicas normales y patológicas

La Tabla 5.1 muestra los porcentajes de precisión clasificación con su desviación estándar, para cada uno de los clasificadores utilizados sobre el segmento diastólico.

TABLA 5.1. Porcentajes de precisión de clasificación para el segmento diastólico

	Knn	nm	qd	f	sv
Diastólico	97.32 ± 1.51	94.65 ± 2.13	95.84 ± 2.0	94.79 ± 2.30	95.84 ± 2.16

En la Figura 5.2 se pueden observar los diagramas de caja 2(a) y las funciones de densidad de probabilidad 2(b) de cada una de las características calculadas sobre el segmento

diastólico. La densidad de probabilidad de la clase normal está graficada en color azul y la de la clase patológica en color verde.

En la Figura se puede notar un solapamiento entre las clases normal y patológica para la dimensión de correlación y el exponente de Lyapunov, siendo este último el de mayor traslape, lo que genera bajos porcentajes de precisión de clasificación como se observa en la Tabla 5.3.

La diferencia entre la media de la dimensión de correlación de la clase normal y de la patológica genera una posible separación entre ambas clases, sin embargo la poca concentración de los valores, los datos atípicos (principalmente de la clase patológica) y el traslape de las clases provoca un valor relativamente bajo del porcentaje de precisión de clasificación (Tabla 5.3).

El exponente de Hurst muestra poco traslape y una diferencia entre las medias de cada clase, lo cual genera una separabilidad entre ellas. Esto se puede verificar por el alto valor del porcentaje de clasificación (Tabla 5.3).

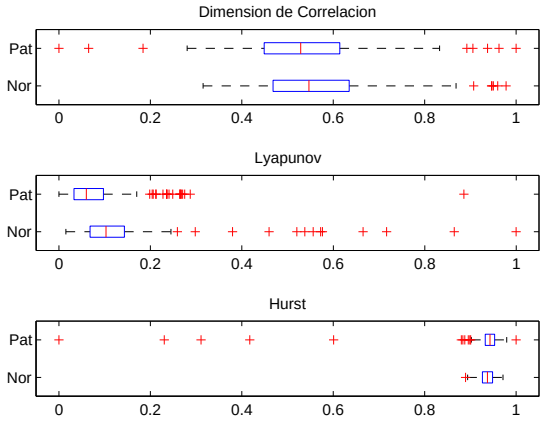

(a) Diagrama de cajas características normales y patológicas

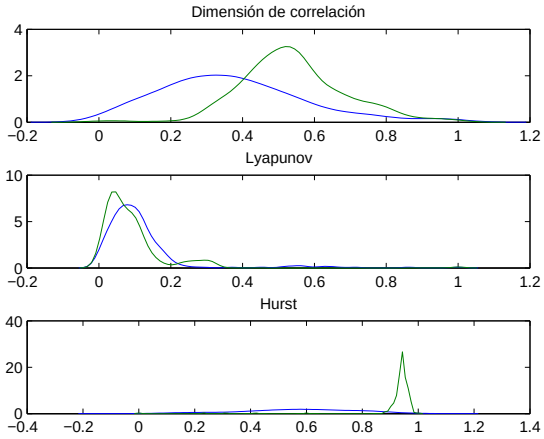

(b) Densidad de probabilidad para cada característica

FIGURA 5.2. Segmento diastólico

Segmento Sistólico

La Figura 5.3 muestra la distribución de las características calculadas sobre el segmento sistólico, se observa la separabilidad entre las clases normal y patológica tanto en la figura como el los porcentajes de precisión de clasificación (ver Tabla 5.2).

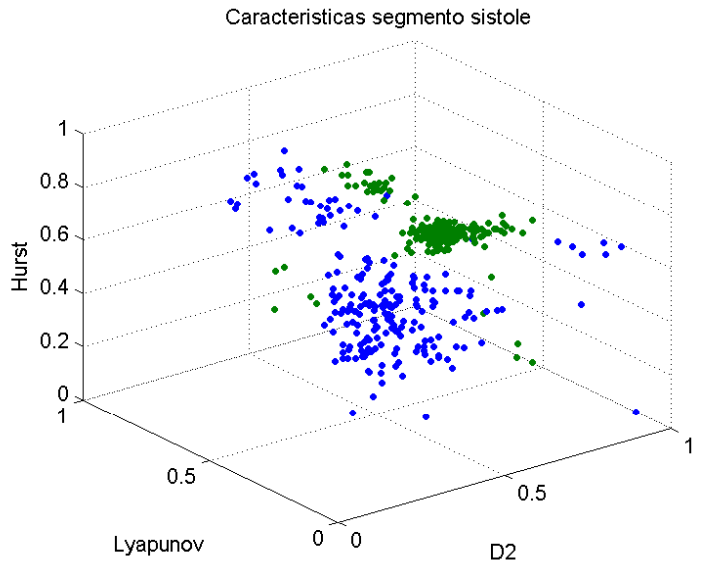

FIGURA 5.3. Distribución de las características sistólicas normales y patológicas

La Tabla 5.2 muestra los porcentajes de precisión de clasificación con su desviación estándar, para el segmento sistólico.

TABLA 5.2. Porcentajes de precisión de clasificación para los segmento Sistólico

	Knn	nm	qd	f	sv
Sistólico	97.8 $\pm$ 0.7	91.04 $\pm$ 1.44	95.07 $\pm$ 1.77	93.40 $\pm$ 1.61	94.44 $\pm$ 1.53

En las Figuras 4(a) y 4(b) se pueden observar los diagramas de caja y las funciones de densidad de probabilidad de cada una de las características calculadas sobre el segmento sistólico, para la clase normal y patológica.

Las características calculadas para el segmento sistólico tienen un comportamiento similar que el segmento diastólico, aunque para el segmento sistólico hay una mayor concentración de los datos para la dimensión de correlación, lo que mejora el porcentaje de precisión de clasificación. El exponente de Lyapunov continua presentando traslape entre las clases y el menor porcentaje de precisión de clasificación. En cuanto al exponente de Hurst se mantiene la tendencia de la concentración de los datos, la diferencia de las medias y el mejor porcentaje de precisión de clasificación.

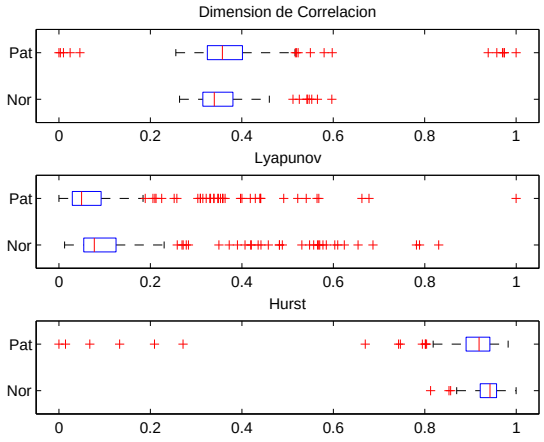

(a) Diagrama de cajas características normales y patológicas

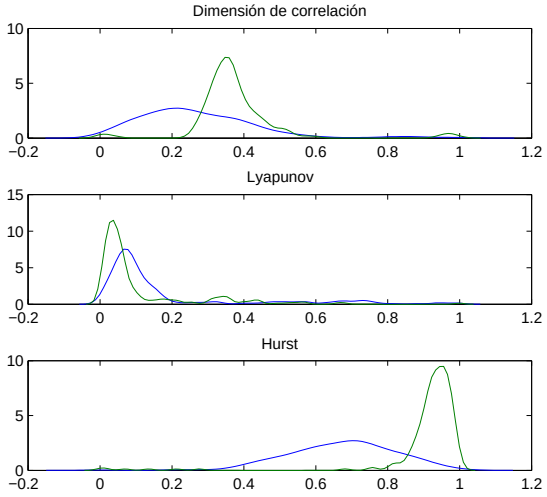

(b) Densidad de probabilidad para cada característica

FIGURA 5.4. Segmento sistólico

Los resultados de las tablas 5.1 y 5.2 muestran que el clasificador de los k vecinos más cercanos ofrece el mejor porcentaje de precisión de clasificación con la menor desviación para los dos segmentos analizados, es por esto que se utiliza este clasificador en las siguientes etapas del análisis con señales FCG cuyos resultados se presentan en las Tablas 5.4 y 5.3.

En la Figura 5.5 se muestra el rendimiento del clasificador k-NN como función del número de vecinos y se concluye que un clasificador 5-NN es el que produce mejores resultados, para las señales FCG.

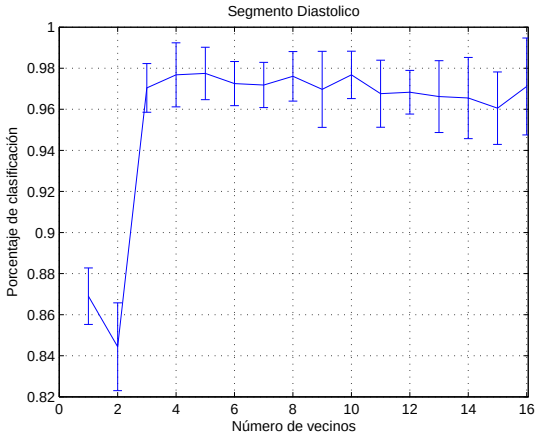

FIGURA 5.5. Rendimiento del clasificador k-NN como función del número de vecinos

Al analizar el desempeño individual en cuanto a porcentaje de precisión de clasificación de cada una de las características se puede decir que el exponente de Hurst ofrece mayor separabilidad entre las clases normal y patológica. Esto se puede verificar al observar los resultados de la Tabla 5.3.

TABLA 5.3. Porcentajes de precisión de clasificación por característica para los segmentos del FCG analizados

	D_2	Lyapunov	Hurst
Diástole	66.89 $\pm$ 2.58	56.62 $\pm$ 3.9	95.99 $\pm$ 1.66
Sístole	71.04 $\pm$ 3.15	64.58 $\pm$ 1.08	89.6 $\pm$ 2.04

Las Figuras 5.6 y 5.7 muestran la distribución en un plano bidimensional de las combinaciones de características (D_2 – Lyapunov, D_2 – Hurst, Lyapunov – Hurst), para los segmentos diastólico y sistólico respectivamente. Se puede observar cómo las combinaciones con el exponente de Hurst permiten mayor separabilidad entre las clases (para ambos segmentos) lo que se puede verificar en los altos porcentajes de precisión de clasificación entre las parejas (D_2 – Hurst) y (Lyapunov – Hurst) para ambos segmentos, ver Tabla 5.4.

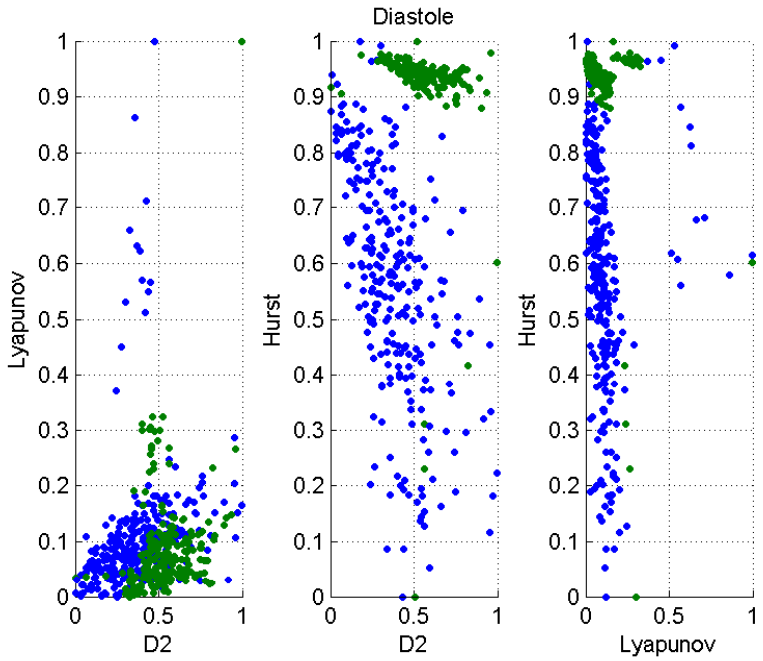

FIGURA 5.6. Distribución parejas de características segmento diastólico

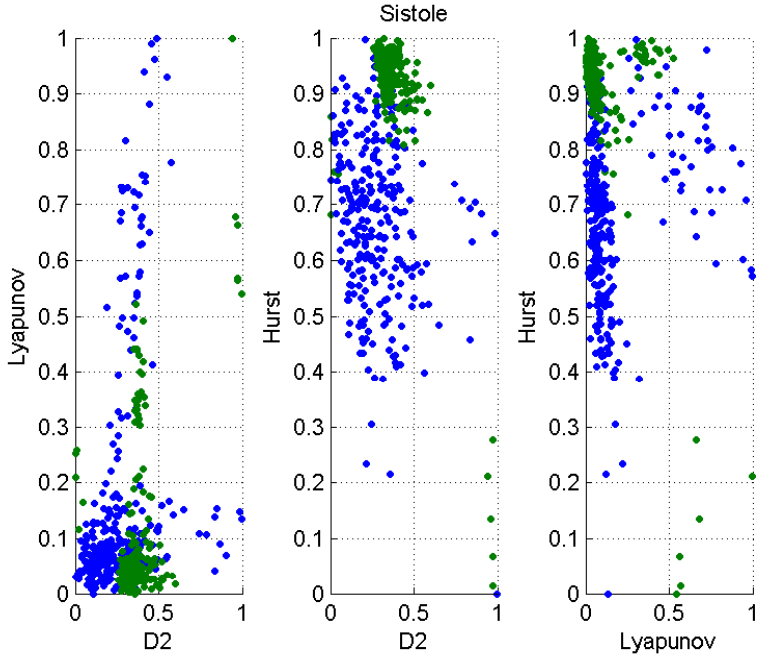

FIGURA 5.7. Distribución parejas de características segmento sistólico

TABLA 5.4. Porcentajes de precisión de clasificación por parejas de características en señales FCG

	D_2 − Lyapunov	D_2 − Hurst	Lyapunov − Hurst
Diástole	79.30 ± 3.27	97.18 ± 1.79	97.25 ± 1.2175
Sístole	85.83 ± 1.54	94.24 ± 1.18	94.23 ± 1.57

Es posible formar una clase normal y una patológica con las características calculadas en ambos segmentos, como se observa en la Figura 5.8 ambas clases están concentradas en nubes de puntos que son visiblemente separables. La Tabla 5.5 muestra los porcentajes de precisión de clasificación obtenidos con los diferentes clasificadores, al igual que en análisis por segmentos el clasificador Knn de 5 vecinos ofrece el porcentaje más alto.

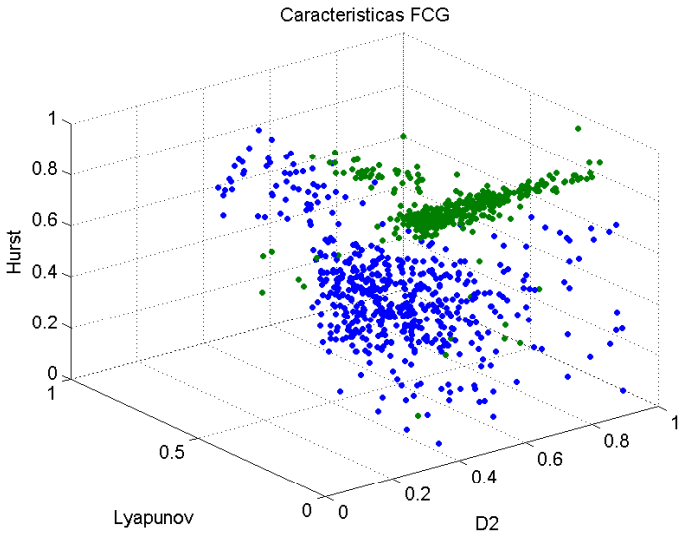

FIGURA 5.8. Distribución de las características en señales FCG normales y patológicas

TABLA 5.5. Porcentajes de precisión de clasificación para las señales de FCG

	Knn	nm	qd	f	sv
FCG	97.6 ± 0.88	92.79 ± 1.8	94.04 ± 1.26	94.29 ± 1.46	94.91 ± 1.45

En el análisis por características realizadas a través del los diagramas de cajas y las funciones de distribución, se puede notar que existe una alta variabilidad en los valores de la dimensión de correlación tanto para la clase normal como para la patológica. Aunque el valor de la media es diferente el traslape entre las clases provoca un porcentaje de precisión de clasificación relativamente bajo (ver Tabla 5.6).
El exponente de Lyapunov presenta poca variabilidad, comparada con la de las otras características, también se puede ver que existe gran cantidad de datos atípicos para ambas clases por encima del tercer cuartil Q_3. El traslape entre las clases es considerablemente grande,

lo cual, evita realizar una separación entre ellas, esto se refleja en el 59.33 de porcentaje de precisión de clasificación, siendo éste el más pequeño.
En cuanto al exponente de Hurst se observa poca variabilidad en los valores de la clase patológica, y una alta para los de la clase normal. Existen datos atípicos para ambas clases por debajo del primer cuartil Q_1. El alto porcentaje de precisión de clasificación obtenido con el exponente de Hurst se debe a la diferencia entre las medianas, y al pequeño traslape entre las clases.

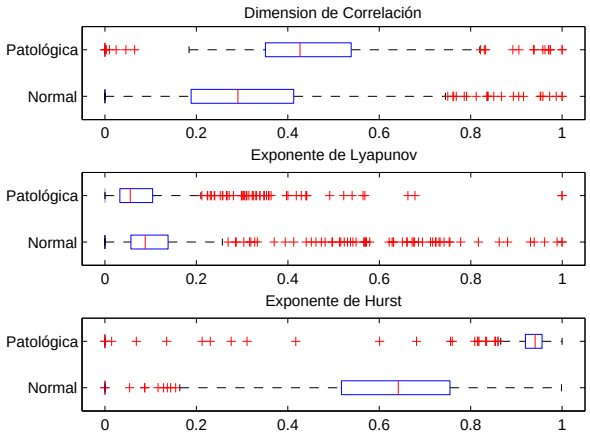

(a) Diagrama de cajas características normales y patológicas

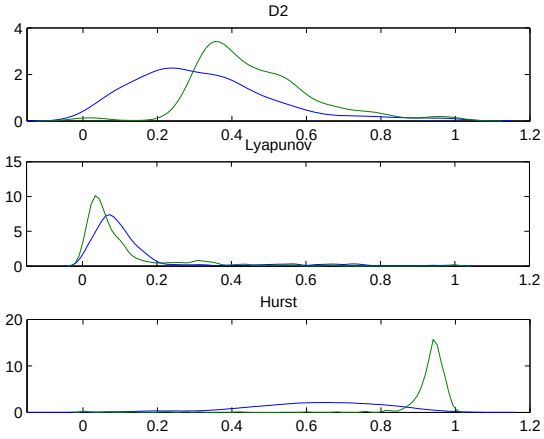

(b) Densidad de probabilidad para cada característica

FIGURA 5.9. Señales FCG

TABLA 5.6. Porcentajes de precisión de clasificación por característica en señales FCG

	D_2	Lyapunov	Hurst
FCG	63.41 $\pm$ 2.16	59.33 $\pm$ 3.33	91.57 $\pm$ 1.37

En la Figura 5.10 se observa la distribución de las diferentes combinación entre las características calculadas. Se pueden diferenciar dos nubes de puntos en cada una de las Figuras. En la Figura de la pareja D_2 – Lyapunov se puede ver que existe un traslape considerablemente grande entre las clases a diferencia de lo que ocurre con las otras dos parejas de características en las que el traslape es mucho más pequeño. El traslape evita la separación ente las clases y es por eso que la pareja en la que este es mayor presenta el menor porcentaje de precisión de clasificación 5.4.

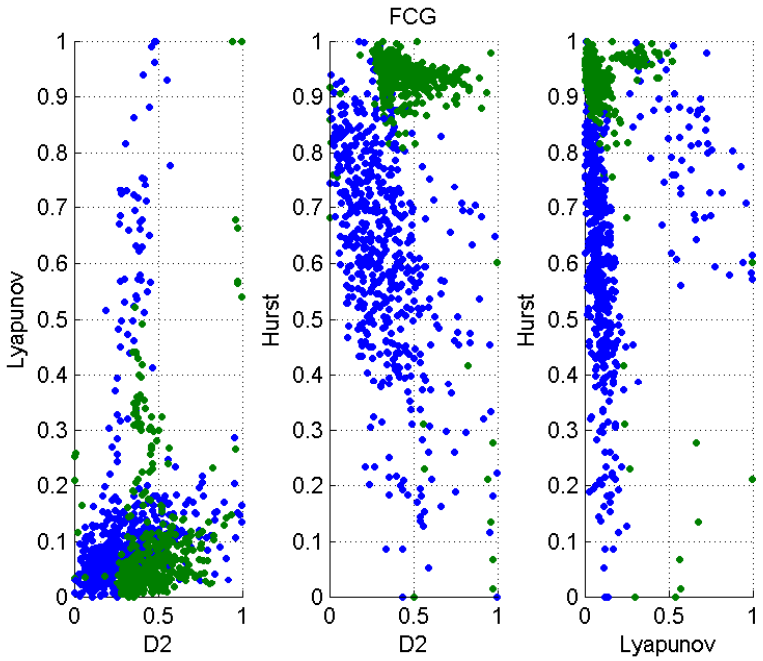

FIGURA 5.10. Distribución parejas de características en señales FCG

TABLA 5.7. Porcentajes de precisión de clasificación por parejas de características en señales FCG

	D_2 – Lyapunov	D_2 – Hurst	Lyapunov – Hurst
FCG	80.63 $\pm$ 2.07	94.80 $\pm$ 1.3	95.01 $\pm$ 0.92

Al igual que al analizar los segmentos del FCG por separados el exponente de Hurst es la característica que ofrece los más altos porcentajes de precisión de clasificación.sectionSeñales Fonocardiográficas

5.1. Señales de Voz

En la Figura 5.11 se puede observar la concentración de las características para las dos clases, en los ejes Lyapunov(y) y Hurst(z), esto se debe a valores bajos de la dimensión de correlación. Los valores de los porcentajes de precisión de clasificación reflejan el traslape entre la clase normal y la patológica (Tabla 5.8), sin embargo el clasificador $k - nn$ y el cuadrático tienen los valores más altos.

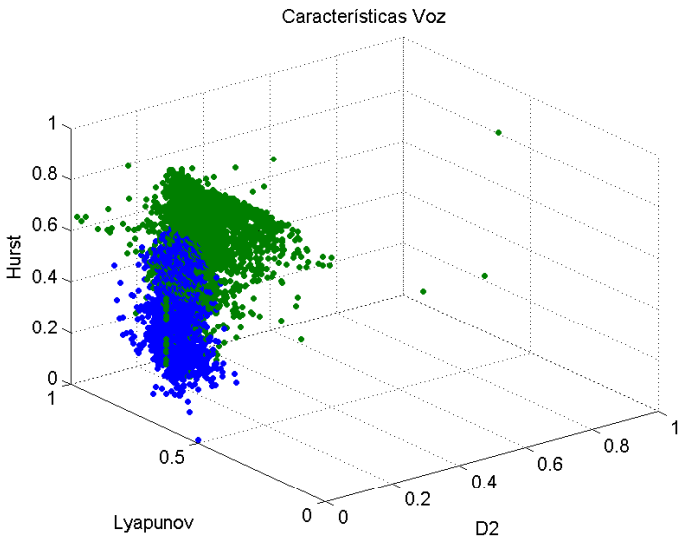

FIGURA 5.11. Distribución de las características en señales de voz normales y patológicas

TABLA 5.8. Porcentajes de precisión de clasificación para las señales de voz

	Knn	nm	qd	f	sv
Voz	90.73 ± 0.46	83.37 ± 0.46	91.75 ± 0.52	87.27 ± 0.54	87.29 ± 0.49

Del diagrama de cajas 12(a) es posible observar la gran concentración de los valores de D_2 en un rango pequeño, sin embargo como se observa en las funciones de densidad 12(b) existe una pequeña diferencia entre las medias de ambas clases para ésta característica, lo que permite realizar una distinción entre voces normal y patológica con un porcentaje de precisión de clasificación relativamente alto (Tabla 5.9). Cabe resaltar la presencia de gran cantidad de datos atípicos en especial en la clase patológica (la presencia de estos atípicos es general para las 3 características en este tipo de señales).

El exponente de Lyapunov presenta un traslape entre las clases, y las funciones de densidad presentan una distribución muy similar en cuanto a media y varianza lo que no permite una separación entre las clases esto se evidencia en el bajo porcentaje de precisión de clasificación (Tabla 5.9).

Por otra parte el Exponente de Hurst muestra poco traslape entre cajas normales y patológicas y medias diferentes lo que genera el más alto porcentaje de precisión de clasificación (Tabla 5.9).

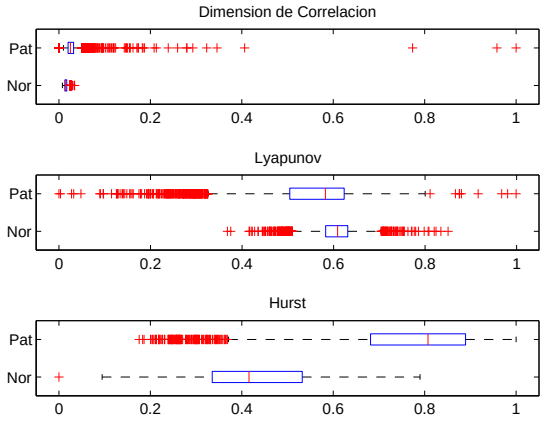

(a) Diagrama de cajas características normales y patológicas

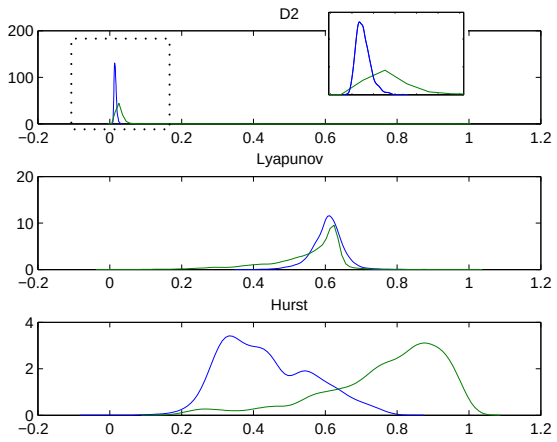

(b) Densidad de probabilidad para cada característica

FIGURA 5.12. Señales de voz

Para las señales de voz, la dimensión de correlación y el exponente de Hurst permiten una gran separabilidad entre la clase normal y patológica, esto se evidencia en los altos valores del porcentaje de precisión de clasificación para estas dos características mostrados en la Tabla 5.9. Los resultados presentados en esta Tabla son los obtenidos con el clasificador $k - nn$, con 5 vecinos, esto se debe a que con este valor al igual que en las señales FCG se obtiene el mayor porcentaje de precisión de clasificación, como se observa en la Figura 5.13.

TABLA 5.9. Porcentajes de precisión de clasificación por característica en señales de voz

	D_2	Lyapunov	Hurst
voz	81.42 $\pm$ 0.86	64.84 $\pm$ 1.35	84.26 $\pm$ 0.08

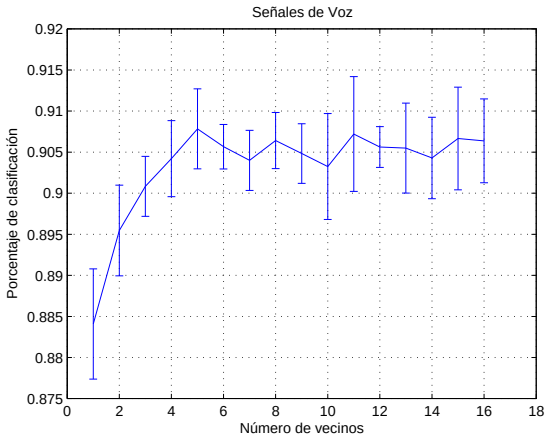

FIGURA 5.13. Rendimiento del clasificador k-NN como función del número de vecinos para señales de voz

La Figura 5.14 muestra la dispersión de las parejas de características, se puede observar cómo la combinación D_2 – Hurst presenta mayor separabilidad entre la clase normal y la patológica que las otras dos combinaciones, esto se puede verificar en la Tabla 5.10 donde esta pareja presenta un valor del porcentaje de precisión de clasificación un poco mayor al de las parejas D_2 – Lyapunov y Lyapunov – Hurst.

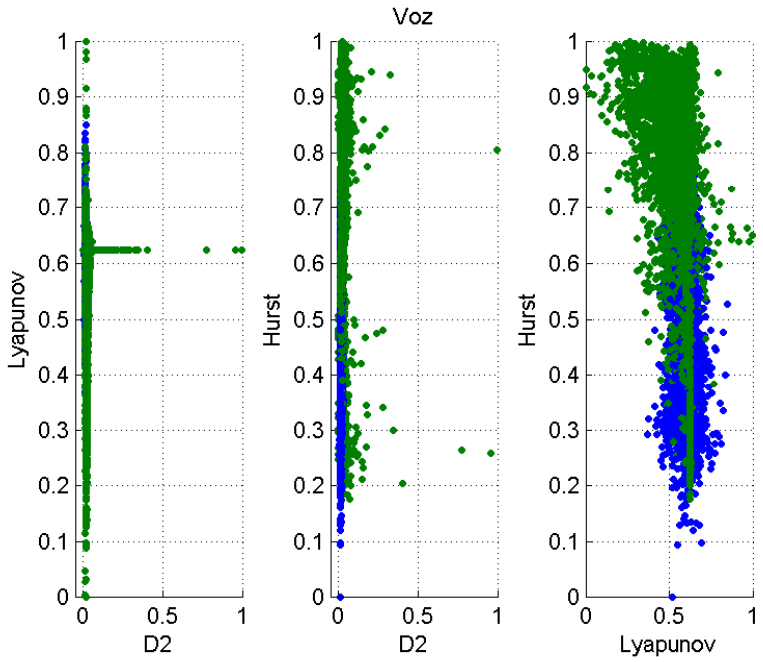

FIGURA 5.14. Distribución parejas de características en señales de voz

TABLA 5.10. Porcentajes de precisión de clasificación por parejas de características en señales de voz

	D_2 − Lyapunov	D_2 − Hurst	Lyapunov − Hurst
voz	86.69 ± 0.66	89.97 ± 0.74	85.83 ± 0.62

La gran cantidad de datos atípicos en las señales de voz principalmente en la clase patológica afecta notablemente la separación entre la clase normal y la patológica.

5.2. Señales Electroencefalográficas

Para el estudio realizado en en este trabajo solo se tuvieron en cuenta la señales normales y las de ataques epilépticos para la clase patológica.

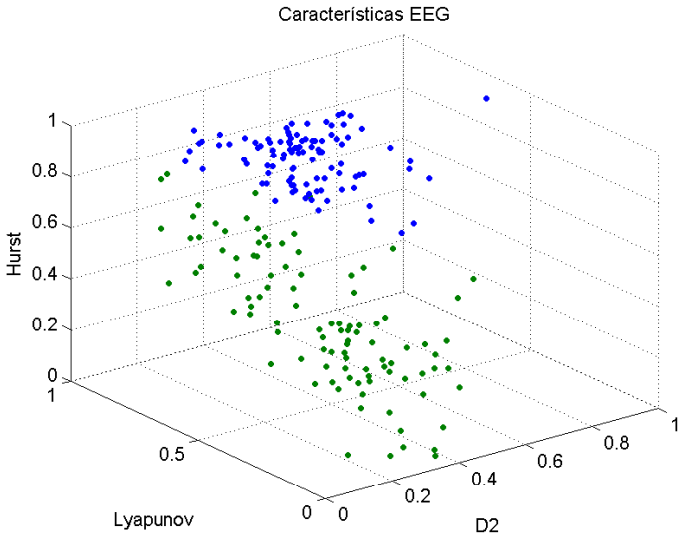

FIGURA 5.15. Distribución de las características en señales EEG normales y patológicas

Para las señales EEG la clase normal y la clase patológica como se observa en la Figura 5.15 son visiblemente separables, aunque los datos de cada una de las clases están muy dispersos en el plano 3-D.

Para esta base de datos los porcentajes de precisión de clasificación son altos para todos los clasificadores utilizados en este trabajo, sin embargo el clasificador de los k vecinos más cercanos sigue ofreciendo los valores más altos (ver Tabla 5.11).

TABLA 5.11. Porcentajes de precisión de clasificación para las señales EEG

	Knn	nm	qd	f	sv
EEG	98.5 $\pm$ 1.46	93.17 $\pm$ 2.99	98.17 $\pm$ 1.66	96.67 $\pm$ 2.08	97 $\pm$ 2.04

El número de vecinos utilizado para lo experimentos resumidos en las siguientes Tablas es 5 este valor fue elegido porque con él se obtienen los mejores porcentajes de precisión de clasificación como se observa en la Figura 5.16

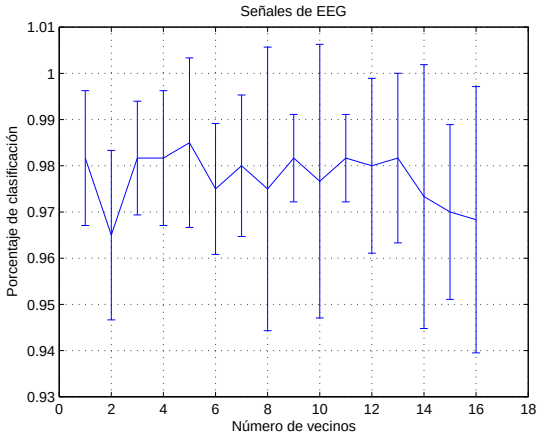

FIGURA 5.16. Rendimiento del clasificador k-NN como función del número de vecinos para señales EEG

En la Figura 5.17 se observa que para las tres características calculadas la media de la clase normal y la patológica son diferentes. Existe un traslape entre ambas clases para la dimensión de correlación y el exponente de Lyapunov a diferencia de exponente de Hurst, estos último para la clase patológica presentan una gran dispersión de los datos.

Por otro lado aunque el exponente de Hurst presenta un pequeño traslape, las medias de ambas clases son notablemente diferentes lo que permite realizar una separación entre ellas, esto se puede verificar en la Tabla 5.12 donde para esta característica se presenta el más alto porcentaje de precisión de clasificación.

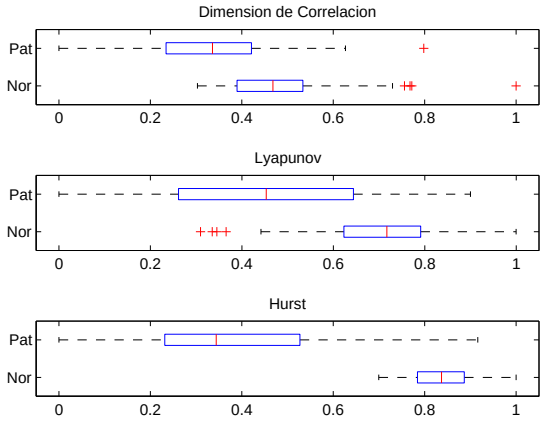

(a) Diagrama de cajas características normales y patológicas

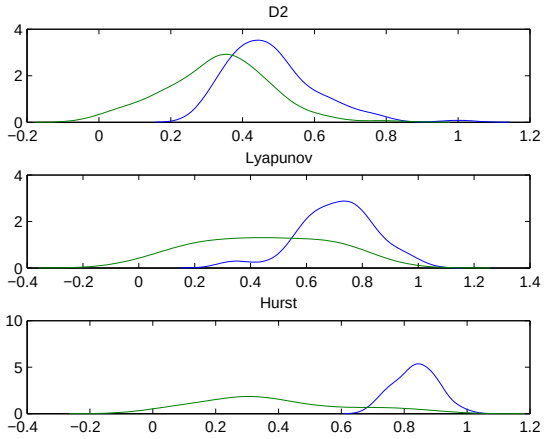

(b) Densidad de probabilidad para cada característica

FIGURA 5.17. Señales EEG

Aunque los porcentajes de precisión de clasificación al evaluar las características de forma individual en general son altos, el exponente de Hurst sigue presentando el valor más elevado, como se ve en la Tabla 5.12.

TABLA 5.12. Porcentajes de precisión de clasificación por característica en señales EEG

	D_2	Lyapunov	Hurst
EEG	70.17 ± 3.80	74.5 ± 4.31	91.17 ± 1.58

Las combinación de características para este tipo de señales presenta altos porcentajes de precisión de clasificación como se puede observar en la Tabla 5.13. Los valores más

altos son para las parejas D_2 – Hurst y Lyapunov – Hurst esto se debe a que la clase normal en azul se concentra en la parte superior del plano como se observa en la Figura 5.18, generando poco traslape con la clase patológica esto se refleja en altos valores del porcentaje de precisión de clasificación.

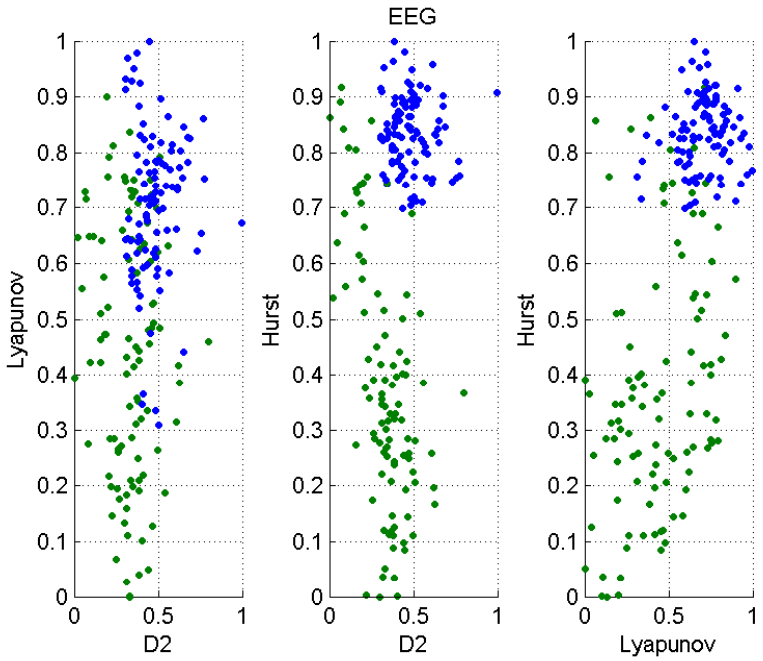

FIGURA 5.18. Distribución parejas de características en señales EEG

TABLA 5.13. Porcentajes de precisión de clasificación por parejas de características en señales EEG

	D_2 – Lyapunov	D_2 – Hurst	Lyapunov – Hurst
EEG	85 ± 3.77	98.67 ± 1.53	91.67 ± 2.94

Después de analizar cada una de las bioseñales, se procede a realizar una comparación de los resultados obtenidos para cada una de las señales. En la Figura 5.19 se presentan diagramas de cajas para cada una de las características por clase (normal y patológica).

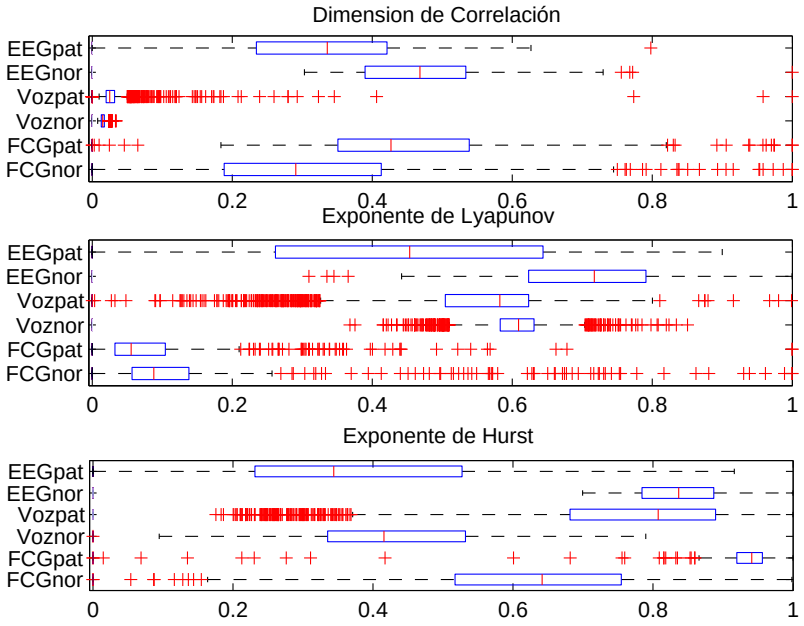

FIGURA 5.19. Diagrama de cajas de las diferentes señales

Del diagrama de cajas se puede observar que la dimensión de correlación para las señales FCG y EEG presenta la mayor variabilidad, caso contrario de las señales de voz en las que ésta es menor. En esta característica existen gran cantidad de datos atípicos en la clase patológica en las señales de Voz principalmente por encima del tercer cuartil (Q_3), en las señales FCG los atípicos se presentan en ambas clases. Se puede observar una diferencia significativa entre los valores de las medianas de los diferentes tipos de señales analizadas.

El exponente de Lyapunov de las señales EEG presenta la mayor variabilidad tanto para la clase normal como para la patológica. Se observa gran cantidad de datos atípicos para todas las señales y para ambas clases. También se puede ver que la mediana de la clase normal en todas las señales es mayor que la de la clase patológica y para los tres tipos de señales los valores de este exponente son visiblemente diferentes siendo los de las señales FCG los más pequeños.

En el diagrama de cajas del exponente de Hurst se observa que los valores obtenidos en las señales FCG de la clase patológica tienen la menor variabilidad. La presencia de datos atípicos es menor a comparación con las otras características.

6. Discusiones

En este trabajo se presenta un metodología para la caracterización de bioseñales mediante el uso de las características convencionales de dinámica no lineal. La metodología fue probada en tres tipos de señales (FGC, Voz y EEG), las cuales tienen morfologías y comportamientos distintos, que son reflejados en la diferencia de los valores de las características de complejidad, por ejemplo el valor de la dimension de correlación para las señales de voz tanto de la clase normal como el de la patológica es el más pequeño. Por otra parte, el exponente de Lyapunov en ambas clases de las señales FCG presenta los valores más pequeños en cuanto a la mediana, en relación al exponente de Hurst cabe resalta la gran diferencia intra clase y entre los tres tipos de señales.
Para las señales FCG se realizaron dos análisis el primero consiste en la evaluación de las características calculas sobre los segmentos diástole y sístole por separado, con el cual se obtiene que la dimensión de correlación para el segmento diastólico es mayor que para el sistólico tanto para la clase normal como para la patológica, lo que indica la mayor complejidad del segmento diastólico. Además según lo que se muestra en las Tablas 5.1 y 5.2 es posible realizar una separación entre las clases normal y patológica tanto de los segmentos diastólicos como de los sistólicos. Para el segundo análisis se formó una clase normal y una patológica con las características de cada clase de ambos segmentos, los resultados muestran que D_2 es mayor en la clase patológica que en la normal, indicando que la primera es mas compleja. En este análisis también se observa que es posible separar la clase normal de la clase patológica (Ver Tabla 5.5). Los resultados obtenidos con FCG son comparables con los presentados en [Delgado et al., 2009] donde el porcentaje de acierto es de 97.17%

Los valores de las características de complejidad en las señales de voz muestran que la dimensión de correlación para la clase normal es menor que el de patológica, este resultado es comparable con el obtenido en [Jiang et al., 2006] donde se utiliza una base datos con patologías similares. Y con el estudio realizado por [Titze et al., 1993] que encontró que la dimensión de correlación de sujetos con disfonías y pólipos es mayor que la de los sujetos sanos.

En las pruebas realizadas sobre las señales EEG se obtuvo un valor máximo del porcentaje de precisión de clasificación del 98.5%, este resultado es comparable con los obtenidos por Übeyli en sus diferentes estudios: [Übeyli and Güler, 2007] 98.60%, [Übeyli, 2008b] 93.71%, [Übeyli, 2008a] 99.30%, [Übeyli, 2009] 98.15%, [Übeyli, 2010] 98.05% que fueron realizados sobre la misma base de datos analizada en este trabajo, con diversas metodologías. Del tamaño los diagramas de cajas de la Figura 17(a) se puede observar que los valores de la características tienen una alta variabilidad, también que existe una gran diferencia entre las medianas de las clases lo que las hace altamente separables esto se evidencia en el valor

del porcentaje de precisión de clasificación.

De los resultados presentados en la Figura 5.19 se puede notar que la dimensión de correlación en EEG para la clase normal es ligeramente mayor que en FCG, caso contrario a lo que ocurre al compararla con las señales de voz de esta misma clase donde la diferencia es muy notable. En la clase patológica el valor más alto de D_2 se presenta en las señales FCG, se observa que ocurre un comportamiento similar que en la clase normal, una pequeña diferencia con las señales EEG y una grande con las señales de Voz.
El exponente de Lyapunov presenta un comportamiento semejante en los tres tipos de señales siendo mayor en la clase normal que en la patológica. Además se observa la mayor dispersion de los datos en las señales EEG y la menor en las señales FCG. Cabe resaltar la presencia de gran cantidad de valores atípicos, para las bases de datos de voz y FCG estos valores atípicos pueden ser causados por el análisis por ventanas y por segmentos realizados a estas señales.
El exponente de Hurst es la característica con mayor diferencia entre las medianas de la clase normal y la patológica en los tres tipos de señales, esto influye en la separabilidad entre las clases y en las Tablas 5.6, 5.9, 5.12 se muestra que para todas las señales esta característica ofrece los mejores porcentaje de precisión de clasificación.
El exponente de Hurst demostró ser la características que provee los mejores desempeños para los tres tipos de señales, caso contrario a lo que ocurre con el Exponente de Lyapunov con el que se obtienen los menores porcentajes de precisión de clasificación.
Las pruebas con señales EEG mostraron los mejores resultados, manifestados en altos porcentajes de precisión de clasificación, una posible causa de este desempeño superior puede ser que el análisis en esta base de datos se realizó sobre toda la señal sin realizar ningún tipo de ventaneo ni segmentación.

7. Conclusión y trabajo futuro

7.1. Conclusiones

En términos generales el uso de las características no lineales clásicas permiten realizar una separación entre la clase normal y la patológica. La dimensión de correlación y el exponente de Hurst ofrecen para los tres tipos de señales buenos porcentajes de precisión de clasificación, el exponente de Lyapunov por si solo no permite una correcta separación entre clases. Sin embargo la combinación de estas tres características genera altos porcentajes de precisión de clasificación lo que indica gran separabilidad entre las clases analizadas. Cabe resaltar que el exponente de Hurst es la característica más discriminate.

El esquema metodológico presentado, mostró desempeños equivalentes a los que se encuentran en el estado del arte tanto en los trabajos realizados dentro del Grupo de Control y Procesamiento Digital de señales, por ejemplo el realizado sobre FCG [Delgado et al., 2009] como en los realizados por fuera [Jiang et al., 2006] y [Übeyli, 2010] sobre señales de voz y EEG respectivamente.

Los resultados obtenidos sugieren que las metodologías implementadas para la detección de estados funcionales en señales FCG, Voz y EEG empleando técnicas de dinámica no lineal como herramientas para su caracterización, puede contribuir a una correcta clasificación entre sujetos sanos y patológicos ya que presentan un alto poder discriminante entre éstas clases, de acuerdo a la capacidad de las medidas aplicadas para establecer márgenes de separabilidad entre casos normales y patológicos.

El análisis de tiempo corto realizado sobre las señales de voz muestra gran cantidad de datos atípicos en D_2, en el exponente de Lyapunov y en el exponente de Hurst. Esto lleva a pensar que este tipo de análisis genera inestabilidad en la estimación de las características de complejidad convencionales, es por esta razón, que se propone el estudio de nuevas características por ejemplo las entropías para la caracterización de este tipo de bioseñales.

7.2. Trabajo futuro

Como trabajo futuro se propone el uso de nuevas características no lineales que ayuden a mejorar las tasas de acierto, tales como las medidas de complejidad basadas en entropías. Se propone además, el uso técnicas de representación (embebimiento), que tengan en cuenta las diferentes periodicidades de las señales en búsqueda de una mejor descripción y análisis de cambio de las mismas.

Bibliografía

[Abarbanel, 1996] Abarbanel, H. D. I. (1996). *Analysis of Observed Chaotic Data*. Springer, N.Y.

[Ahlstrom et al., 2006] Ahlstrom, C., Hule, P., Rask, P., Karlsson, J., Nylandre, E., Dahlstrom, U., and Ask, P. (2006). Feature extraction for systolic heart murmur classification. *Annals or Biomedical Engineering*, pages 1666–1677.

[Andrzejak et al., 2001] Andrzejak, R. G., David, P., Elger, C. E., Lehnertz, K., Mormann, F., and Rieke, C. (2001). Indications of nonlinear deterministic and finite dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. *Physical Review E*.

[Andrzejak et al., 2006] Andrzejak, R. G., Mormann, F., Widman, G., Kreuz, T., Elger, C., and Lehnertz, K. (2006). Improved spatial characterization of the epileptic brain by focusing on nonlinearity. *Epilepsy Research*, 69(1):30–44.

[Avila, 2003] Avila, J. B. (2003). Análisis de la actividad elétrica cerebral en pacientes epilépticos. Master's thesis, Pontificia Universidad Javeriana.

[Baker and Gollub, 1990] Baker, G. L. and Gollub, J. P. (1990). *Chaotic dynamics : an introduction*. Cambridge University Press, Cambridge [England].

[Banbrook et al., 1999] Banbrook, M., McLaughlin, S., and Mann, I. (1999). Speech characterization and synthesis by nonlinear methods. *Speech and Audio Processing, IEEE Transactions on*, 7(1):1 –17.

[Berraondo et al., 2001] Berraondo, P., Perez, J., Elizalde, P., Ortuño, F., Teijeira, J., and Díaz, E. (2001). Dinámica no lineal en el análisis de electrocardiogramas. *Física Medica*.

[Übeyli, 2008a] Übeyli, E. D. (2008a). Analysis of eeg signals by combining eigenvector methods and multiclass support vector machines. *Computers in Biology and Medicine*, 38(1):14 – 22.

[Übeyli, 2008b] Übeyli, E. D. (2008b). Wavelet/mixture of experts network structure for eeg signals classification. *Expert Systems with Applications*, 34(3):1954 – 1962.

[Übeyli, 2009] Übeyli, E. D. (2009). Analysis of eeg signals by implementing eigenvector methods/recurrent neural networks. *Digital Signal Processing*, 19(1):134 – 143.

[Übeyli, 2010] Übeyli, E. D. (2010). Lyapunov exponents/probabilistic neural networks for analysis of eeg signals. *Expert Systems with Applications*, 37(2):985 – 992.

[Übeyli and Güler, 2007] Übeyli, E. D. and Güler, I. (2007). Features extracted by eigenvector methods for detecting variability of eeg signals. *Pattern Recognition Letters*, 28(5):592 – 603.

[Bracic and Stefanoska, 1998] Bracic, M. and Stefanoska, A. (1998). Nonlinear dynamics of the blood flow studied by lyapunov exponents. *Bulletin of Mathematical Biology*, 60(417-433).

[Carvajal et al., 2002] Carvajal, R., Vallverdú, M., Baranowski, R., Batanowska Orlowska, R., Zebrowski, J. J., and Caminal, P. (2002). Dynamical non-linear analysis of heart rate variability in patients with aortic stenosis. *Computers in Cardiology*, 29:449–452.

[Carvajal et al., 2005] Carvajal, R., Wessel, N., andP. Caminal, M. V., and Voss, A. (2005). Correlation dimension analysis of heart rate variability in patients with dilated cardiomyopathy. *Comput Methods Programs Biomed*, 78(2):133–140.

[Casaleggio et al., 1990] Casaleggio, A., Morando, M., Pestelli, S., and Ridella, S. (1990). Study of the correlation dimension of' ecg signals based on mit-bih arrhythmia data base ecgs. *Computers in Cardiology,*.

[Cerquera, 2005] Cerquera, E. A. (2005). Caracterización de estados funcionales en fonocardiografía empleando análisis acústico y técnicas de dinámica no lineal. Master's thesis, Universidad Nacional de Colombia Sede Manizales.

[Cheitlin and Skolow, 1993] Cheitlin, M. and Skolow, D. (1993). *Clinical Cardiology*. Prentice Hall international Inc.

[Chen and Yau, 1998] Chen, C.-L. and Yau, H.-T. (1998). Chaos in the imbalance response of a flexible rotor supported by oil film bearings with non-linear suspension. *Nonlinear Dynamics*, 16:71–90. 10.1023/A:1008239206153.

[Cobeta and Tapia, 1996] Cobeta, I. and Tapia, R. G. (1996). Diagnóstico y tratamiento de los trastornos de la voz. In Garci, editor, *Ponencia oficial de la SEORL*.

[Contreras-Troya, 2007] Contreras-Troya, T. (2007). Análisis fractal de un sistema complejo:epilepsia. Master's thesis, Escuela Superior de Ingeniería Mecánica y Eléctrica. Instituto Politécnico Nacional.

[Contreras-Troya et al., 2006] Contreras-Troya, T. I., Morales-Matamoros, O., Balankin, A., and Sandoval, R. (2006). Epilepsy as a dynamic system. In *Memorias del 4º Congreso Internacional de Ingeniería Electromecánica y de Sistemas. Escuela Superior de Ingeniería Mecánica y Eléctrica. Instituto Politécnico Nacional.*

[Contreras-Troya et al., 2009] Contreras-Troya, T. I., Morales-Matamoros, O., Trueba-Ríos, B., Tejeida-Padilla, R., and Balankin, A. (2009). Análisis fractal de la epilepsia. *Científica*, 13(2):85–94.

[Cross and Hohenberg, 1993] Cross, M. and Hohenberg, P. (1993). Pattern formation outside of equilibrium. *Reviews of Modern Physics*, 65(3):851–1122.

[Delgado, 2008] Delgado, E. (2008). *Generación y extracción/selección de características en la detección automática de isquemia y deficiencias valvulares sobre registros de la actividad cardíaca.* PhD thesis, Universidad Nacional de Colombia sede Manizales.

[Delgado et al., 2009] Delgado, E., Manrrique, A. F. Q., Llorente, J. I. G., Velasco, M. B., and Dominguez, G. C. (2009). Digital auscultation analysis for heart murmur detection. *Annals of Biomedical Engineering*, 37:337–353.

[Delgado-Trejos et al., 2009] Delgado-Trejos, E., Castellanos-Domínguez, C. G., and Vallverdú-Ferrer, M. (2009). *Análisis de relevancia en espacios de representación orientado al soporte de diagnóstico*, volume 1 of *Notas de Automática Avanzada*. Facultad de Ingeniería y Arquitectura, Universidad Nacional de Colombia Sede Manizales, Manizales, Colombia.

[Diambra et al., 2001] Diambra, L., Malta, C. P., Capurro, A., and Fernández, J. (2001). Nonlinear structures in electroencephalogram signals. *Physica A: Statistical Mechanics and its Applications*, 300(3-4):505 – 520.

[Dokoumetzidis et al., 2001] Dokoumetzidis, A., Iliadis, A., and Macheras, P. (2001). Nonlinear dynamics and chaos theory: Concepts and applications relevant to pharmacodynamics. *Pharmaceutical Research*, 18:415–426.

[Durand and Pibarot, 1995] Durand, L. and Pibarot, P. (1995). Digital signal processing of the phonocardiogram: Review of the most recent advancements. *Critical Reviews in Biomedical Engineering*, 23(3/4):163–219.

[Eye and E.I.L.MEEIVL, 1994] Eye, M. and E.I.L.MEEIVL (1994). Voice disorders database. versión 1.03.

[Faure and Korn, 2003] Faure, P. and Korn, H. (2003). Is there chaos in the brain? i.concepts of nonlinear dynamics and methods of investigation. *Comptes Rendus Biologies*, 324:773–793.

[Ganong, 2006] Ganong, W. F. (2006). *Fisiología Médica*. Manual Moderno, 20 edition.

[Ghafari et al., 2008] Ghafari, S., Golnaraghi, F., and Ismail, F. (2008). Effect of localized faults on chaotic vibration of rolling element bearings. *Nonlinear Dynamics*, 53:287–301. 10.1007/s11071-007-9314-2.

[Gollub and Langer, 1999] Gollub, J. and Langer, J. (1999). Pattern formation in nonequilibrium physics. *Reviews of Modern Physics*, 71(2):S396–S403.

[Grassberger and Procaccia, 1983] Grassberger, P. and Procaccia, I. (1983). Characterization of strange attractors. *Physical Review Letters*, 50(5):346–349.

[Guillén et al., 2001] Guillén, P., Vallverdú, M., Jugo, D., Carrasco, H., and Caminal, P. (2001). Dinámica no lineal para caracterizar la variabilidad del ritmo caríaco en pacientes chagásico. In *Congreso Latinoamericano de Ingeniería Biomédica*.

[Henry et al., 2000] Henry, B., Lovell, N., and Camacho, F. (2000). Nonlinear dynamics time series analysis. In Akay and Metin, editors, *Nonlinear Biomedical Signal Processing - Dynamic Analysis and Modeling*, volume II. Wiley-IEEE Press.

[Holyst and Zebrowska, 2000] Holyst, J. and Zebrowska, M. (2000). Recurrence plots and hurst exponents for financial markets and foreign-exchange data. *International Journal of Theoretical and Applied Finance*, 3(3):419.

[Hou and Li, 2010] Hou, S. and Li, Y. (2010). Detecting nonlinearity from a continuous dynamic system based on the delay vector variance method and its application to gear fault identification. *Nonlinear Dynamics*, 60:141–148. 10.1007/s11071-009-9586-9.

[Jiang and Zhang, 2002] Jiang, J. and Zhang, Y. (2002). Nonlinear dynamic analysis of speech from pathological subjects. *Electronics Letters*, 38(6):294 –295.

[Jiang and Chen, 1999] Jiang, J. D. and Chen, J. (1999). The application of correlation dimension in gearbox condition monitoring. *Journal of Sound and Vibration*, 223(4):529–541.

[Jiang et al., 2006] Jiang, J. J., Zhang, Y., and McGilligan, C. (2006). Chaos in voice, from modeling to measurement. *Journal of Voice*, 20(1):2 – 17.

[Kantz and Schreiber, 2004] Kantz, H. and Schreiber, T. (2004). *Nonlinear Time Series Analysis*. University of Cambridge, second edition.

[Kikuchi et al., 2006] Kikuchi, A., Shimizu, T., Hayashi, A., Horikoshi, T., Unno, N., Kozuma, S., and Taketani, Y. (2006). Nonlinear analyses of heart rate variability in normal and growth-restricted fetuses. *Early Human Development*, 82(4):217 – 226.

[Korn and Faure, 2003] Korn, H. and Faure, P. (2003). Is there chaos in the brain? ii.experimental evidence. *Comptes Rendus Biologies*, 326:787–840.

[Logan and Mathew, 1996] Logan, D. and Mathew, J. (1996). Using the correlation dimension for vibration fault diagnosis of rolling element bearings i. basic concepts. *Mechanical Systems and Signal Processing*, 10(3):241–250.

[Manrrique, 2009] Manrrique, A. F. Q. (2009). Análisis tiempo-frecuencia por métodos no paramétricos orientado a la detección de patologías en bioseñales. Master's thesis, Universidad Nacional de Colombia sede Manizales.

[Manrrique et al., 2009] Manrrique, A. F. Q., Llorente, J. I. G., Velasco, M. B., and Dominguez, G. C. (2009). Selection of dynamic features based on time–frequency representations for heart murmur detection from phonocardiographic signals. *Annals of Biomedical Engineering*.

[Mansilla, 2003] Mansilla, R. (2003). *Introducción a la econofísica*. Equipo Sirius.

[Morillo, 2008] Morillo, D. S. (2008). *Procesado y trabsmisión de señales biomédicas para el diagnóstico de trastornos y enfermedades del sueño*. PhD thesis, Universidad de Cádiz.

[Morillo,] Morillo, L. Análisis visual del electroencefalograma. In *7 Guía Neurológica*, pages 143–163.

[Nigam and Priemer, 2005] Nigam, V. and Priemer, R. (2005). Accessing heart dynamics to estimate durations of heart sound. *Physiol Meas*, pages 1005–1018.

[Nitish et al., 2004] Nitish, V., Thakor, N. T., and Tong, S. (2004). Advances in quantitative electroencephalogram analysis methods. *Annual Review of Biomedical Engineering*, 6(453-495).

[Pallikari and Boller, 1999] Pallikari, F. and Boller, E. (1999). A rescaled range analysis of random events. *Journal of Scientific Exploration*, 13(1).

[Parker and Chua, 1987] Parker, T. S. and Chua, L. O. (1987). Chaos: A tutorial for engineers. In *IEEE Proceedings*, volume 75, page 982–1008.

[Parsa and Jamieson, 2000] Parsa, V. and Jamieson, D. G. (2000). Identification of pathological voices using glottal noise measures. *Journal of Speech, Language, and Hearing Research*, 43(2):469–485.

[Peng et al., 1995] Peng, C.-K., Havlin, S., Hausdorff, J., Mietus, J., Stanley, H., and Goldberger, A. (1995). Fractal mechanisms and heart rate dynamics: Long-range correlations and their breakdown with disease. *Journal of Electrocardiology*, 28(Supplement 1):59 – 65.

[Peters, 1989] Peters, E. (1989). Fractal structure in the capital markets. *Financial Analysts Journal*, 45(4):32–37.

[Peters, 1992] Peters, E. (1992). R/s analysis using logarithmic returns. *Financial Analysts Journal*, 48(6):81–82.

[Pitsikalis et al., 2003] Pitsikalis, V., Kokkinos, I., and Maragos, P. (2003). Nonlinear analysis of speech signals: Generalized dimensions and lyapunov exponents. In *in Proc. of Eurospeech*.

[Pradhan et al., 1995] Pradhan, N., Narayana, D. D., Sadasivan, P. K., and Satish, M. (1995). Analysis of the chaotic characteristics of sleep eeg patterns from dominant lyapunov

exponent. In *Proc. of 14th Conference of the Biomedical Engineering Society of India*, volume 3.

[Rodríguez et al., 2008] Rodríguez, A., Sanmartín, J. P., Giraldo, E., Orozco Gutiérrez, A. Á., and Fetecua, J. G. (2008). Interpretación dinámica de bioseñales usando técnicas de análisis no lineal. In *Memorias STSIVA 2008*, volume II, pages 89–94.

[Rondón, 2002] Rondón, P. G. (2002). *Análisis de la dinámica no lineal y cambios de complejidad en la variabilidad del ritmo cardíaco y en señales electroencefalográficas*. PhD thesis, Universidad Politécnica de Cataluña.

[Rouviere, 2001] Rouviere, H. (2001). *Compendio de anatomia y diserccion*. Masson S.A, 3 edition.

[Rowan and Tolunsky, 2004] Rowan, A. J. and Tolunsky, E. (2004). *Conceptos básicos sobre EEG con mini-atlas*. Elsevier.

[Sackellares et al., 1999] Sackellares, J. C., Iasemidis, L. D., Gilmore, R. L., and Roper, S. N. (1999). Epilepsy - when chaos fails. In *in: Chaos in Brain? Interdisc. Workshop*, pages 10–12.

[Sauer et al., 1991] Sauer, T., Yorke, J., and Casdagli, M. (1991). Embedology. *Journal of Statistical Physics*, 65:579–616.

[Savi, 2005] Savi, M. A. (2005). Chaos and order in biomedical rhythms. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, XXVII(2):157 –169.

[Spasic et al., 2008] Spasic, S., Culic, M., Grbic, G., Martac, L., Sekulic, S., and Mutavdzic, D. (2008). Spectral and fractal analysis of cerebellar activity after single and repeated brain injury. *Bulletin of Mathematical Biology*, 70:1235–1249. 10.1007/s11538-008-9306-5.

[Takens, 1981] Takens, F. (1981). Detecting strange attractors in turbulence. In Springer-Verlag, editor, *Dynamical Systems and Turbulence, Lecture Notes in Mathematics*, volume 898, pages 366–381.

[Titze et al., 1993] Titze, I., R, B., and H, H. (1993). *Vocal Fold Physiology: New Frontiers in Basic Science*, chapter Evidence of chaos in vocal fold vibration, pages 143–188. San Diego, CA: Singular Publishing Group.

[Voss et al., 1996] Voss, A., Kurths, J., Kleiner, H., Witt, A., Wessel, N., Saparin, P., Osterziel, K., Schurath, R., and .Dietz, R. (1996). The application of methods of non-linear dynamics for the improved and predictive recognition of patients threatened by sudden cardiac death. *Cardiovascular Research*, 31:419–433.

[Wang et al., 2001] Wang, W. J., Chen, J., Wu, X. K., and Wu, Z. (2001). The aplication of some non-linear methods in rotating machinery fault diagnosis. *Mechanical Systems and Signal Processing*, 15:0888–3270.

[Zhang and Jiang, 2003] Zhang, Y. and Jiang, J. J. (2003). Nonlinear dynamic analysis in signal typing of pathological human voices. *Electronics Leters online*, 39(13):1021 – 1023.

[Zhang et al., 2005] Zhang, Y., Jiang, J. J., Biazzo, L., and Jorgensen, M. (2005). Perturbation and nonlinear dynamic analyses of voices from patients with unilateral laryngeal paralysis. *Journal of Voice,*, 19(4):519–528.