



**UNIVERSIDAD POPULAR AUTÓNOMA DEL
ESTADO DE PUEBLA**

Centro Interdisciplinario de Posgrados

Doctorado en Ingeniería Biomédica

**Caracterización No Lineal de
Señales Biomédicas en
Patologías Específicas: EEG**

Tesis que para obtener el grado de

Doctor en Ingeniería Biomédica

Presenta

Alfonso Medel Rojas

Director Interno: Manuel González Pérez

Director Externo: Tomás Morales Acoltzi

Noviembre 2013



UPAEP – Secretaría General

Dirección General de Apoyos Académicos

Dirección del Centro de Recursos para el Aprendizaje y la Investigación.

Biblioteca Central - **Karol Wojtyla**

Tesis Digitales Restricciones de uso:

DERECHOS RESERVADOS ©

PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de textos, imágenes, gráficas, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente de donde la obtuvo mencionando el autor o autores involucrados en el documento.

Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.



Universidad Popular Autónoma del Estado de Puebla

Centro Interdisciplinario de Posgrados

Investigación y Consultoría

Doctorado En Ingeniería Biomédica

Se aprueba la Tesis:

Caracterización No Lineal de Señales Biomédicas en
Patologías Específicas: EEG

Comité Asesor

Dr. Tomás Morales Acoltzi

Director Externo de Tesis

Dr. Manuel González Pérez


Director Interno de Tesis

Dr. Juan Manuel López Oglesby

Asesor de Tesis

Puebla, México.

23 de noviembre de 2013



Universidad Popular Autónoma del Estado de Puebla
Centro Interdisciplinario de Posgrados
Investigación y Consultoría

Doctorado En Ingeniería Biomédica

Se aprueba la Tesis:

Caracterización No Lineal de Señales Biomédicas en
Patologías Específicas: EEG

Comité Asesor


Dr. Tomás Morales Acoltzi

Director Externo de Tesis



Dr. Manuel González Pérez

Director Interno de Tesis



Dr. Juan Manuel López Oglesby

Asesor de Tesis

Puebla, México.

23 de noviembre de 2013

Caracterización No Lineal de Señales Biomédicas en Patologías Específicas: EEG

Dedicatorias

Esta tesis se la dedico al creador, quién supo guiarme por el buen camino, darme fuerzas para seguir adelante y no desmayar en los problemas que se presentaban, enseñándome a encarar la adversidad sin desfallecer en el intento.

A mi Esposa Yanet, a mis hijos Zara y Pablo, y a mis padres por su apoyo, consejos, comprensión, amor, ayuda en los momentos difíciles, con los recursos necesarios para estudiar.

Me han dado todo lo que soy como persona, mis valores, mis principios, mi carácter, mi empeño, mi perseverancia, mi coraje para conseguir mis objetivos.

Agradecimientos

A las personas que me enseñaron compartiéndome sus conocimientos, estudiando no para saber más, ni ser mejor que otros, tan sólo para superarme. Por todo eso gracias, porque ustedes son mis maestros y amigos.

CONACYT

Nuestro agradecimiento por habernos otorgado una beca para los estudios del Doctorado en ingeniería Biomédica, en la Universidad Popular Autónoma Del Estado De Puebla **UPAEP**, durante el periodo de enero del 2009 a diciembre de 2012.

H. Puebla de Z., a 23 de Noviembre de 2013

Asunto: Agradecimiento por el apoyo recibido de
Becas Tesis 2013

Consejo de Ciencia y Tecnología del Estado de Puebla

PRESENTE

Sirva este medio para avalar que el suscrito **"Alfonso Medel Rojas"** fungió como beneficiario(a) del Programa Becas – Tesis CONCYTEP 2013, el cual tiene el objetivo de brindar estímulos económicos a estudiantes de educación superior en instituciones del Estado de Puebla que busquen obtener su título profesional vía defensa de tesis entre los meses de septiembre a noviembre de 2013.

En mi carácter de beneficiario(a) del programa antes citado, extendiendo un cordial agradecimiento al Consejo de Ciencia y Tecnología del Estado de Puebla (CONCYTEP) por el incentivo económico otorgado, mismo que permitió satisfactoriamente la elaboración y conclusión de la tesis titulada **"Caracterización No Lineal de Señales Biomédicas en Patologías Específicas: EEG"**, mediante la cual se obtuvo el grado de **"DOCTOR"** en **"Ingeniería Biomédica"** por la **"Universidad Popular Autónoma del Estado de Puebla UPAEP"**.

Aprovecho la ocasión para certificar que el monto total de las cinco ministraciones concernientes al apoyo otorgado por el CONCYTEP consintió en \$24,000.00 (veinticuatro mil pesos 00/100 M.N.).

No omito comentar que la existencia de Programas y actividades encaminadas al desarrollo profesional de los estudiantes de instituciones de educación superior en el Estado de Puebla, como el programa del cual fui beneficiario, desencadenan buenas prácticas para elevar el nivel de competitividad y productividad en nuestro Estado, y por esto no dudo en reiterar mi más sincero agradecimiento.

Atentamente

Alfonso Medel Rojas
Beneficiario del Programa de Becas Tesis 2013

Resumen

El cuerpo humano frecuentemente produce señales que pueden ser medidas y analizadas. Estas señales biológicas son tratadas con modelos matemáticos lineales, donde, se busca reducir el tiempo de muestreo y de análisis, a cambio de la pérdida de características, que a la larga pueden ser relevantes para su estudio, como el caso de los Electroencefalogramas (EEGs)¹.

En el caso de las patologías que pueden ser observadas con la ayuda de los **EEGs**, tenemos: el alcoholismo, epilepsia, apnea, etc., para nuestro trabajo iniciaremos con el alcoholismo, dejando como trabajos futuros otras patologías. El camino que recorrimos con este trabajo, nos podrá ayudar en futuras investigaciones a enfocar las metodologías idóneas para obtener buenos resultados, en las otras patologías detectables con el **EEGs**.

Conocemos que el cerebro utiliza el azúcar presente en la sangre como combustible, pero también puede utilizar otras sustancias como el ácido acético (acetato). Sin embargo, el consumir una cantidad elevada de alcohol con el estómago vacío, puede disminuir rápidamente el azúcar presente en la sangre de una persona, y el ácido acético es capaz de compensar el combustible que deja de estar disponible para el cerebro, lo cual crea el incentivo para seguir bebiendo. Las personas que habitualmente consumen mucho alcohol tienen una capacidad aún mayor para conseguir esa energía extra. Los efectos del acetato en el cerebro, por consumo excesivo de alcohol, pueden promover la dependencia, porque si la gente deja de beber, no sólo pierde el alcohol, sino también el acetato. Si el cerebro se ha adaptado a tener esa sustancia en su entorno, el bebedor puede sufrir síntomas de abstinencia. En resumen, tendremos una afectación neta en las personas consumidoras de alcohol identificables, ayudándonos como testigos a las personas no consumidoras².

Usando las señales de los **EEG**, buscamos tener una referencia de algún daño neuronal que nos permita diferenciar, personas con problemas de alcoholismo y personas normales. Las señales de **EEG's**, contienen información que permite identificar diferentes procesos (químicos, electroquímicos, biológicos y fisiológicos, donde 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) y alteraciones en las células nerviosas.

En las recientes décadas se ha tenido un gran desarrollo de modelos matemáticos para el estudio de los sistemas no-lineales con aplicaciones en el área de medicina³⁻¹⁴. Simultáneamente han aparecido cajas de herramientas para el análisis de series de tiempo no-lineales¹⁵, pudiéndose clasificar en dos categorías, aplicaciones gráficas y aplicaciones modo consola¹⁶. En el primer caso funciona como una caja negra, pues no hay modo de saber cómo hace los cálculos; por ejemplo, uno de los paquetes más usados es el **VRA** (Visual Recurrence Analysis) y **CDA** (Chaos Data Analysis), entre otros; En el segundo caso sólo genera datos numéricos, como **TISEAN**¹⁶, faltando la fase gráfica para la interpretación.

El alcohol sobre el sistema nervioso, provoca una dependencia biológica, alteraciones metabólicas y sinápticas que pueden conducir a severos daños de las células nerviosas, entre otras consecuencias^{17,18}.

En trabajos futuros buscaremos correlacionar algunos otros tipos de daños ocasionados por otros narcóticos y sus afectaciones.

Índice General

<i>Dedicatorias</i>	<i>3</i>
<i>Agradecimientos.....</i>	<i>4</i>
<i>Resumen</i>	<i>6</i>
<i>Índice de Figuras</i>	<i>10</i>
<i>Índice de Tablas/Cuadros</i>	<i>12</i>
<i>Capítulo I Introducción</i>	<i>13</i>
1.1 Definición del problema.....	13
1.2 Justificación	14
1.3 Hipótesis	14
1.4 Objetivos.....	16
1.4.1 Objetivo General	16
1.4.2 Objetivo Específicos.....	16
1.5 Alcances y Limitaciones.....	16
<i>Capítulo II Antecedentes.....</i>	<i>18</i>
2.1 Antecedentes y trabajos relacionados	18
2.2 Bioseñales	20
2.2.1 Señales de Electroencefalograma (EEG).....	20
2.2.2 Descripción Fisiológica.....	21
2.2.3 Neuronas	23
2.2.3.1 Ultraestructura Funcional de la Neurona:.....	25
2.2.3.2 Somas o Pericarion.....	26
2.2.3.3 Dendritas.....	26
2.2.3.4 Axón.....	27
2.2.3.5 Nervio Periférico.....	27
<i>Capítulo III Datos y Metodología.....</i>	<i>29</i>

3.1 Cuerpo de Datos.....	29
3.2 Teoría de sistemas dinámicos	35
3.2.1 Los sistemas dinámicos.....	35
3.2.2 Sistemas dinámicos discretos.....	36
3.3 Teoría Lógica Combinatoria.....	42
3.3.1 Fundamentos.....	43
3.3.2 Criterios de comparación.....	45
3.3.2.1 Creación de los criterios de comparación.....	45
3.3.3 Creación de la Matriz Básica (MB).....	49
3.3.4 Cálculo del Testor Típico.....	50
3.5 Redes Neuronales Artificiales.....	53
3.5.1 La red incremental RCE.....	54
<i>Capítulo IV Resultados y Discusión.....</i>	<i>56</i>
4.1 Resultados preliminares con la D_2	56
4.2 Resultados finales con D_2	59
4.3 Resultados finales con Información Mutua.....	61
<i>Capítulo V Conclusiones</i>	<i>63</i>
5.1 Conclusiones.....	63
5.2 Trabajos futuros	65
<i>Anexo A Descomprimir los EEG</i>	<i>66</i>
<i>Anexo B Código fuente de GWBASIC</i>	<i>68</i>
<i>Anexo C Tablas de Resultados</i>	<i>70</i>
<i>Anexo D Código en Matlab.....</i>	<i>74</i>
<i>Bibliografía</i>	<i>75</i>

Índice de Figuras

Figura 2.1 Muestra de una señal electrocardiográfica normal ⁴¹	21
Figura 2.2 Lóbulos del cerebro ⁴²	22
Figura 2.3 Las neuronas del cerebelo de una paloma ⁴³	24
Figura 2.4 Estructura de la Neurona ⁴⁴	25
Figura 2.5 Ramificaciones del nervio periférico ⁴⁵	28
Figura 3.1 Estándar 10-20 de 64 electrodos de EEG ⁴⁶	30
Figura 3.2 Archivos del cuerpo de datos completo	31
Figura 3.3 Contenido del archivo co2a0000425.rd.006	33
Figura 3.4 Gráfica de segundos continuos en el cuerpo de datos	34
Figura 3.5 Resultados de la ecuación de la información mutua en un EEG	38
Figura 3.6 Matriz con valores de la Información Mutua de los EEG	39
Figura 3.7 Herramienta probada con datos teóricos de Lorenz	41
Figura 3.8 Matriz con valores de la Dimensión de Correlación de los EEG	42
Figura 3.9 Matriz de Aprendizaje	44
Figura 3.10 Conjunto de valores admisibles al rasgo	44
Figura 3.11 Representación de los criterios de comparación	48
Figura 3.12 Creación de la MD usando δ	49
Figura 3.13 Creación de la MB, usando la MD	50
Figura 3.14 Aplicación del algoritmo BT	53
Figura 3.15 Arquitectura de la red RCE	54
Figura 4.1. Valores de D2 para las 64 derivaciones	56
Figura 4.2. Ubicación del electrodo F2 en las 64 derivaciones	57
Figura 4.3. Gráficas de punto, dimensión de atractor en 2D y 3D, con delay $\tau = 13, 16, 12, 14$ y 9	58
Figura 4.4. Gráficas de punto, dimensión de atractor en 2D y 3D, con delay $\tau = 19, 16, 17, 21$ y 23	59
Figura 4.5 Gráficas del reconocimiento con la D2	60
Figura Anexo-A.1 Archivo completo de EEG para descomprimir	66

<i>Figura Anexo-A.2 Archivo completo de EEG opciones para descomprimir.....</i>	<i>66</i>
<i>Figura Anexo-A.3 Descomprimiendo archivo completo de EEG.....</i>	<i>67</i>
<i>Figura Anexo-A.4 Todos los archivo de EEG.</i>	<i>67</i>
<i>Figura Anexo-B.4 Ejemplo de GWBASIC</i>	<i>68</i>
<i>Figura Anexo-D.1 Esquema General de los programas.....</i>	<i>74</i>

Índice de Tablas/Cuadros

<i>Tabla 4.1 resultados preliminares de D_2.</i>	57
<i>Tabla Anexo C.1 Validación cruzada con 2 grupos para D_2.</i>	70
<i>Tabla Anexo C.2 Validación cruzada con 3 grupos para D_2.</i>	70
<i>Tabla Anexo C.3 Validación cruzada con 4 grupos para D_2.</i>	71
<i>Tabla Anexo C.4 Validación cruzada con 5 grupos para D_2.</i>	71
<i>Tabla Anexo C.5 Validación cruzada con 2 grupos para Mutual.</i>	72
<i>Tabla Anexo C.6 Validación cruzada con 3 grupos para Mutual.</i>	72
<i>Tabla Anexo C.7 Validación cruzada con 4 grupos para Mutual.</i>	73
<i>Tabla Anexo C.8 Validación cruzada con 5 grupos para Mutual.</i>	73

Capítulo I Introducción

Desde que Hans Berger realizara el primer EEGs en 1929, esta técnica ha ido experimentando una progresiva evolución, y ha quedado totalmente aceptada como método de evaluación de la función cerebral en situaciones normales y patológicas. El registro de la actividad eléctrica cerebral es de gran ayuda en la evaluación de encefalopatías, lesiones focales cerebrales, el estudio de la maduración cerebral en niños, por supuesto, en el diagnóstico y seguimiento del paciente con diferentes enfermedades cerebrales, por ejemplo: epilepsia.

1.1 Definición del problema

Las adicciones entre la población de 19 a 29 años, cada vez son más comunes y algunas como el alcoholismo son socialmente aceptadas, en la ciudad de Puebla, el índice de jóvenes que toman este tipo de bebidas, es cada vez mayor según la Encuestas Nacionales de Adicciones 2008 y 2011¹⁹. Los resultados de esta encuesta, particularmente, la adicción al alcohol, se detallan en este capítulo.

La adicción al alcohol trae graves consecuencias y daños a las células neuronales del cerebro, por ello es necesario identificar el daño causado a cada persona o paciente, debido a que en este rango de edad, las personas a un son inmaduras y fácilmente influenciables, teniendo como consecuencia lamentables las siguientes:

- Más del 13% de la población presenta síndrome de dependencia al alcohol.
- 12.5 % son hombres y 0.6% son mujeres entre 18 y 65 años de edad.
- Principal causante de accidentes con un 70 %, 60 % de los traumatismos.
- El 80 % de los divorcios están asociados del alcoholismo.
- Representa el 11.3% de la carga total de enfermedades.

- 49 % de los suicidios.
- El 38 % de los homicidios en el país son cometidos por estar bajo sus efectos.
- Entre jóvenes de 15 y 25 años de edad, los accidentes ocupan la primera causa de mortalidad.

1.2 Justificación

Cinco de cada diez habitantes consume alcohol, el problema se agudiza entre la población de los 19 a 29 años de edad, situación por la cual la ciudad de Puebla ocupa el tercer lugar nacional con este padecimiento (2008), después de Pachuca y Tlaxcala, Fuente: Encuestas Nacionales de Adicciones 2002, 2008 y 2011¹⁹.

Por patrón de consumo, se observaron variaciones importantes de 2002 a 2011 ya que el consumo diario disminuyó (1.4% a .8%), el índice de bebedores consuetudinarios fue similar (5.6% a 5.4%) y el porcentaje de dependencia se incrementó significativamente (4.1% a 6.2%). Por sexo, las tendencias son muy similares ya que de 2002 a 2011, la dependencia aumentó en los hombres (8.3% a 10.8%) y en las mujeres se triplicó (0.6% a 1.8%).

Tomando en cuenta que el consumo excesivo de bebidas alcohólicas, son la principal causa de muchas enfermedades y de delitos sociales, desencadenados por la inhibición que esta bebida provoca, además de los daños neurológicos que causa, es importante diagnosticar que tan grave son, por ello usar una herramienta que nos permita determinar esta gravedad es fundamental, ya que los jóvenes de 19 a 29 años, difícilmente aceptaran que grado de dependencia al alcohol tiene.

1.3 Hipótesis

El uso de la metodología Dimensión de Correlación (D_2) no lineal permitirá la clasificación de EEGs para diferenciar entre Electroencefalogramas de Pacientes

Alcohólicos (EEG-A) y Electroencefalogramas de Pacientes Controlados (EEG-C) con una confianza mayor al 85% en todos los casos.

Ya que esta característica no lineal nos permite tener un valor de complejidad para cada serie muestreada, entre mayor el valor mayor la complejidad, por ello decimos que una persona sana, debe tener un valor mayor a una no sana.

El uso de la metodología Lógica combinatoria (LC) permitirá la clasificación de EEGs para diferenciar entre EEG-A y EEG-C con número reducido de puntos de medida, manteniendo la confianza mayor al 85% en todos los casos.

La LC, nos permite hacer una reducción de la dimensión de los datos garantizando la clasificación, ya que por definición del Testor Típico, nos dice que es un subconjunto de características irreducibles.

El uso de la metodología LC permitirá la clasificación de EEGs para diferenciar entre EEG-A y EEG-C con igual o mayor porcentaje de reconocimiento que metodologías establecidas como lo es el PCA.

El PCA al igual que la LC, reducen la dimensión de muestras, facilitando el reconocimiento o clasificación de los datos, la diferencia fundamental entre ambas metodologías radica en que el PCA, trabaja con toda la matriz de datos y cada vez que agregue datos esta se tendrá que calcular, La LC, trabaja con los datos y sólo se calcula 1 sola vez, ya que nos muestra las características importantes sin haceles transformaciones.

1.4 Objetivos

Desarrollaremos una Software y/o herramientas que nos permita estudiar el comportamiento no-lineal de las series de tiempo del **EEG**, de personas alcohólicas, con predisposición genética al alcoholismo y personas no alcohólicas, con predisposición genética al alcoholismo (esto quiere decir que alguno de los padres y/o abuelos son alcohólicos).

1.4.1 Objetivo General

Desarrollaremos una Software que analice las series de tiempo de los **EEGs**, para determinar el grado de daño provocado por bebidas alcohólicas, usando las técnicas de la teoría de sistemas dinámicos (teoría de caos), particularmente el análisis de la dimensión del atractor.

1.4.2 Objetivo Específicos

- Analizar los **EEG** y extraerle características no-lineales.
- Reconocer los posibles patrones obtenidos con las características no-lineales, calculándole los testores típicos, bajo el enfoque de la Lógica Combinatoria.
- Seleccionar el mejor testor típico (en caso de encontrar más de uno).
- Clasificar las muestras de **EEG** con una red neuronal artificial (**RCE**).
- Hacer validación cruzada de 2, 3, 4 y 5 grupos para mostrar la robustez del trabajo.

1.5 Alcances y Limitaciones

1.5.1 Alcances: Están determinados por la pertinencia y el rango de acción de cada una de las técnicas y/o métodos empleados, ya que trabajamos con series de tiempo, es decir son datos discretos, **NO CONTINUOS**, las metodologías deben ser apropiadas y bien fundamentadas, por ello hemos decidido usar los métodos no

lineales ya que su base fundamental es trabajar con este tipo de series de tiempo, a de más que no desprecia la información aparentemente poco significativa.

1.5.2 Limitaciones: Están en función con la calidad de los datos recabados, ya que al hacer un análisis detallado sólo encontramos 10 segundos continuos de muestreo para la gran mayoría de datos de los pacientes.

Capítulo II Antecedentes

Recientemente las investigaciones científicas han vislumbrado una nueva área de oportunidad, con los sistemas dinámicos no-lineales, ya que la teoría de caos tiene como precepto hacer un análisis más robusto, al no basarse en los métodos que tiene como fundamento la ecuación de la línea recta; estas técnicas buscan representar mejor los datos, formas y comportamientos de los sistemas naturales y así tener una mejor interpretación, mejorando las posibles soluciones.

2.1 Antecedentes y trabajos relacionados

El EEG contiene información sobre la condición del cerebro. Su forma de la onda contiene información útil sobre su estado. Sin embargo, el técnico humano no puede controlar directamente los detalles sutiles. Es difícil de identificar los cambios en estos cambios "sutiles pero críticos", en la forma de onda del EEG mediante la inspección visual. Lo que abre un vasto campo de investigación para los ingenieros biomédicos en el desarrollo y puesta en práctica de varios algoritmos inteligentes para la identificación de tales cambios²⁰⁻²⁵.

Como las bio-señales son muy subjetivas, los síntomas pueden aparecer de forma aleatoria en la escala del tiempo. Las señales de EEG son no lineales y no estacionarias, su naturaleza contribuye a complejidades adicionales relacionadas con su interpretación manual y la detección de las actividades normales y anormales²⁶. Las características no lineales son capaces de capturar los fenómenos fisiológicos complejos, tales como transiciones abruptas y el comportamiento caótico en las señales de EEG²⁷⁻³².

En sus inicios La geometría fractal percibida por Mandelbrot, trataba de emular las formas que la misma naturaleza usaba, su gran virtud no fue el de modelarla matemáticamente, sino, el comprendes que a través de reglas básicas de repetición de formas, se obtenían formas complejas, como las que la naturaleza utiliza para economizar recursos y energía³³. Un fractal como Mandelbrot lo describe es: “Una forma fragmentada o aparentemente irregulares”, que guarda una gran autosimilitud, ya que si lo vemos a diferentes escalas son similares.

Su trabajo inspiro a muchos, desde ingenieros, astrónomos, cineastas, etc. Que lograron grandes descubrimientos y adelantos, tanto en la tecnología como en teorías. Algunos ejemplos son las antenas de los celulares que tiene formas fractales para captar señales en diferentes frecuencias, crear diseños de ropa como en los 70s y 80s, animaciones de mundos virtuales como en viaje a las estrellas, los descubrimientos de la complejidad de en imágenes médicas e incluso algunos patrones en la medida de señales fisiológicas:

Por ejemplo en: Los trastornos del sueño, usando el espacio de fase y espectros de potencia, para analizar EEG se puso a prueba diferentes longitudes de época que van desde 3 a 30-seg. La comparación mostró que el enfoque de espacio de fases da un mejor rendimiento en el caso de cortos como estándar 30-seg longitudes época³⁴.

Sin en cambio, existen otras aplicaciones donde es necesario hacer registros de EEG de larga duración. Haciendo transmisión de señales de EEG sin pérdida de información. Es Fundamental para las aplicaciones basadas en la telemedicina. En trabajos recientes propusieron un esquema de compresión sin pérdidas³⁵. Basándose en predictores de redes neuronales, utilizando el concepto de dimensión de correlación

Otro padecimiento muy común es: La apnea del sueño (es un trastorno como somnolencia diurna, irritabilidad y falta de concentración). Las características no lineales implementadas en investigaciones recientes consistieron en: análisis de fluctuación sin tendencia (**DFA**), Dimensión de correlación (**DC**), 3 Máximos Exponentes de Lyapunov (**LLEs**) y la entropía espectral (**SE**). La propuesta de función final presento el 94,8% de precisión en el conjunto de datos de la apnea del sueño utilizando un kernel basado **SVM** clasificador³⁶⁻³⁹.

Todas estas teorías y metodologías fueron alcanzadas gracias a la persistencia de ir más lejos de lo que ya conocemos. Al cuestionar las formas geométricas tradicionales (euclidianas).

2.2 Bioseñales

El cuerpo humano es un conjunto de múltiples 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, los movimientos de las extremidades y la producción de la voz, frecuentemente producen señales que pueden ser medidas y analizadas. A continuación se describe la bio-señal utilizada en este trabajo.

2.2.1 Señales de Electroencefalograma (EEG)

La electroencefalografía es el 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 problemas⁴⁰. En la Figura 2.1 se muestra un EEG normal.




Figura 2.1 Muestra de una señal electroencefalográfica normal⁴¹.

2.2.2 Descripción Fisiológica

El cerebro es un órgano altamente complejo, que está compuesto de millones de células especializadas 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

visión, el pensamiento; y el movimiento muscular dependen de estos estímulos nerviosos. El cerebro humano está dividido por dos hemisferios (Derecho e Izquierdo), cada hemisferio está subdividido en lóbulos como se muestra en la Figura 2.2




Figura 2.2 Lóbulos del cerebro⁴²

- **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 área sensorial externa relacionada a la percepción de los sentidos, sensibilidad, presión, temperatura y dolor.
- **Lóbulo occipital:** Encargado del área visual y creación de imágenes.

2.2.3 Neuronas

Las neuronas o células nerviosas miden en término medio entre 4-125 micras. Son células muy excitables, especializadas para la recepción de estímulos y la conducción del impulso nervioso. Su tamaño y forma varían considerablemente.

Cada una posee un cuerpo celular desde cuya superficie se proyectan una o más prolongaciones. Las partes responsables de recibir información y conducirla hacia el cuerpo celular se denominan dendritas. La neurona conduce impulsos desde el cuerpo celular hacia la periferia se denomina axón. Estas estructuras se muestran en las Figuras 2.3 y 2.4.




Figura 2.3 Las neuronas del cerebelo de una paloma⁴³.

En la Figura 2.3 se muestra el dibujo de Santiago Ramón y Cajal de las neuronas del cerebelo de una paloma (A) Célula de Purkinje, un ejemplo de neurona bipolar (B) célula granular que es multipolar.




Figura 2.4 Estructura de la Neurona⁴⁴.

2.2.3.1 Ultraestructura Funcional de la Neurona:

Soma: Sintetiza Neurotransmisores y diferente tipo de moléculas.

Dendritas: Son las principales áreas receptoras de impulsos a través de apéndices denominados espinas.

Axón o neurita: Es la prolongación más voluminosa y conduce los impulsos nerviosos en sentido calorífugo.

Cono Axónico: Inicia el Impulso Nervioso (carece de RER).

2.2.3.2 Somas o Pericarion

Los somas forman la sustancia gris, junto a las prolongaciones mielíticas, abundantes células de glía y por sobre todo por abundantes capilares (que le da el color característico). Los capilares forman una red capilar en el soma neuronal y prolongaciones a objeto de transportar los nutrientes para el metabolismo aeróbico, principalmente oxígeno y glucosa.

Están formados por las siguientes estructuras:

- Núcleo
- Citoplasma
- Aparato de Golgi
- Mitocondrias
- Neurofibrillas
- Microtúbulos
- Lisosomas
- Centríolos
- Lipofusina
- Melanina

2.2.3.3 Dendritas

Son prolongaciones que salen del soma y tienen una estructura similar a la del citoplasma. Es el área receptora principal, es corta y contiene cuerpos o grumos de Nissl. Aumentan considerablemente la superficie de contacto de la neurona a través de sus ramificaciones y espinas dendríticas las cuales le dan una apariencia rugosa. Su conducción de impulsos es de tipo **celulípeto**

2.2.3.4 Axón

Es la prolongación larga de la Neurona. Su estructura es diferente a la de la dendrita porque está constituida por un paquete de neurofilamentos y neurotúbulos envueltos en una membrana llamada axolema. Se origina en el cono axónico donde se da inicio al impulso nervioso. Está recubierto por mielina. Tiene ramas colaterales y termina en los llamados botones terminales. Los cuales forman parte de las sinapsis con otras neuronas o bien con células musculares.

Su conducción de impulsos es de tipo **celulífuga**.

Dependiendo del número de prolongaciones se pueden distinguir neuronas unipolares, bipolares y multipolares.

En su estructura se observa un flujo de sustancias, en su mayoría neurotransmisores sintetizados a nivel del soma neuronal y llevadas a las terminaciones axónicas y desde aquí vuelven al soma neuronal en un flujo continuo (flujo anterógrado como retrógrado).

2.2.3.5 Nervio Periférico

Está constituido por paquetes de fibras nerviosas que se agrupan por una envoltura externa que es tejido conectivo y que se denomina Epineuro, por el cual van los vasos sanguíneos que recorren el nervio y le dan nutrición.

Por dentro del epineuro, están los paquetes de fibras envueltas por un tejido fibroso resistente formado por fibras colágenas y elásticas que es Perineuro; el cual es tan resistente, que si hay lesión del epineuro con conservación del perineuro, se conserva la función del nervio.

Dentro de cada fascículo de fibras nerviosas se encuentra otro tejido conectivo, que envuelve cada una de las fibras y se denomina Endoneuro ver Figura 2.5.

Por debajo del endoneuro se encontrará la vaina de Schwann, la mielina y la fibra nerviosa. La vaina de mielina en el nervio periférico se forma por enrollamiento sucesivo de la célula de Schwann alrededor de la fibra nerviosa, y cada cierto tiempo va dejando espacios que se denominan Nodos de Ranvier, que permiten la conducción Saltatoria del impulso nervioso, lo que explica por qué la conducción es más rápida en un nervio con mielina .




Figura 2.5 Ramificaciones del nervio periférico⁴⁵

Capítulo III Datos y Metodología

En este capítulo describiremos el cuerpo de datos, su adquisición y técnicas para su tratamiento y clasificación; iniciamos con el análisis de los archivos, su extracción, segmentación, formateo, filtrado y posteriormente con el reconocimiento de característica, para finalizar con la clasificación usando una red neuronal.

3.1 Cuerpo de Datos

Los datos usados para este trabajo fueron descargados del sitio:

<http://archive.ics.uci.edu/ml/datasets/EEG+Database> (Rev. 19/10/2013)

Obtenidos por, Henri Begleiter en el Laboratorio de Neurodinámica en la Universidad Estatal de Nueva York en el Centro de Salud de Brooklyn (Henri Begleiter at the Neurodynamics Laboratory at the State University of New York Health Center at Brooklyn).

Estos datos surgen de un estudio a gran escala, para examinar la correlación de los EEGs, y la predisposición genética al alcoholismo. Contiene medidas de 64 electrodos colocados en la cabeza de los sujetos, se tomaron las muestras a 256 Hz (3,9 msec época) durante 1 segundo.




Figura 3.1 Estándar 10-20 de 64 electrodos de EEG⁴⁶.

Los dos grupos de personas: alcohólico y de control. Fueron expuestos a un único estímulo (S1) o a dos estímulos (S1 y S2), estos estímulos eran imágenes de objetos seleccionados por Snodgrass⁴⁷.

Había 122 sujetos y cada sujeto completó 120 ensayos en los diferentes estímulos se muestran. Las posiciones de los electrodos se ubicaron en los sitios estándar (Standard Electrode Posición nomenclatura, American Asociación electroencefalográfica 1990). Zhang describe en detalle el proceso de recolección de datos⁴⁸.

Hay tres versiones del conjunto de datos EEG.

1. **El conjunto de datos pequeño:** El pequeño conjunto de datos (smni97_EEG_data.tar.gz) contiene datos para los 2 sujetos, a_co2a0000364 alcohólico y control c_co2c0000337.
2. **El conjunto de datos grande:** El conjunto de datos de gran tamaño (SMNI_CMI_TRAIN.tar.gz y SMNI_CMI_TEST.tar.gz) contiene datos de 10 sujetos de control alcohólicas y 10.
3. **El conjunto de datos completo:** Este conjunto de datos contiene los 120 juicios por 122 sujetos. El conjunto de datos está a unos 700 MBytes.

Para nuestra investigación seleccionamos este último, ya que es el más completo, aunque en la descripción dice: ...NOTA: Hay 17 ensayos con archivos vacíos en co2c1000367. Algunos ensayos hay "erro"




Figura 3.2 Archivos del cuerpo de datos completo.

Y no es el único paciente incompleto, como mostraremos más adelante. Por tal motivo nuestra primera tarea fue revisar la composición de los datos, que es la siguiente:

- 1) Cada paciente tiene un número de expediente (ejemplo co2c1000367), esta comprimido en un archivo.
- 2) Cada expediente comprimido, lo integran 120 archivo (no es el caso de todos), ya que cada archivo contiene la información de 1 seg (256 valores) de cada electrodo de un total de 64.
- 3) Cada archivo tiene un formato especial:
 - a) Que inicia con el número del paciente.
 - b) El número de muestra y electrodos.
 - c) El tiempo de muestreo para cada valor.
 - d) El tipo de estímulo y segundo de muestreo.
 - e) El segundo, el electrodo, el tiempo de muestreo y el valor.




Figura 3.3 Contenido del archivo co2a0000425.rd.006.

Procesando los datos de cada uno de los archivos, encontramos que no están todos los segundos muestreados, intentando obtener los registros de datos más largos, programamos una rutina para verificar cuantos segundos continuos tenemos por paciente, resultando la gráfica siguiente, donde 10 segundo continuos nos proporcionaron 97, pacientes de los 122 que inicialmente tiene el cuerpo de datos.




Figura 3.4 Gráfica de segundos continuos en el cuerpo de datos.

Al identificar los 97 pacientes finales, iniciamos la integración de los datos ya que contamos con 2560 valores por 64 electrodos de los 97 pacientes, obteniendo una matriz de datos tridimensional de $97 \times 64 \times 2560$.

El primer procesamiento formal realizado a los datos fue restarle la tendencia. A cada una de las muestras, es decir, a cada serie de cada paciente; le calculamos su frecuencia media con la transformada rápida de Fourier, al reconstruir la señal solo con su primer armónico, y restárselo al original nos garantiza eliminar la tendencia.

Este procedimiento es un aporte de nuestro trabajo, ya que la mayoría de investigaciones lo omiten o no lo hacen, para encontrar el algoritmo de cómo reconstruir una serie de datos usando el primer armónico o los N primeros armónicos de la transformada de Fourier, anexamos en el **ANEXO B**, donde ponemos el código del y la corrida del programa **GWBASIC**, que realiza dicha operación, la cual fue traducida al lenguaje **MATLAB**.

3.2 Teoría de sistemas dinámicos

El Caos se ha descubierto de manera relativamente reciente gracias, en parte, a las computadoras. En 1961, el meteorólogo Edward Lorenz estaba intentando predecir el clima. Para lograrlo necesitaba resolver numéricamente unas ecuaciones, que modelaban el comportamiento de la atmósfera. Se dio cuenta de que cada vez que ejecutaba su programa, la computadora obtenía resultados diferentes, como solución al sistema de ecuaciones. Lo que ocurría era que su programa trabajaba con seis cifras decimales de precisión, mientras que él introducía como condición inicial sólo tres. Las tres restantes, eran introducidas aleatoriamente por el ordenador en cada ejecución. Aunque Lorenz conocía esto, no pensaba que un error de inicialización en las milésimas fuera a importar mucho en el resultado final. Se había topado con un sistema de ecuaciones caótico.

El Caos viene a desbancar definitivamente con una idea bastante antigua, el determinismo. Desde los tiempos de Newton, disponemos de una teoría matemática capaz de predecir el comportamiento de los sistemas físicos. Conociendo la configuración inicial de un sistema y aplicando una serie de reglas (las leyes de la física), el comportamiento de un sistema está totalmente determinado en un instante posterior. La teoría del Caos nos advierte que, en determinados sistemas físicos, la evolución temporal es tremendamente compleja y depende dramáticamente de las condiciones iniciales hasta el punto de que no podamos predecir con seguridad la evolución real del sistema³³.

3.2.1 Los sistemas dinámicos

La teoría del Caos se enmarca dentro del estudio de los sistemas dinámicos. Empezaremos por definir el espacio de fases. Éste es el conjunto configuraciones posibles de un sistema dado. Algunos ejemplos:

Para un péndulo, una configuración está determinada por el conocimiento del ángulo θ y la velocidad ω (no basta sólo el ángulo). El espacio de fases tendrá dimensión 2.

Para un tiro parabólico, la configuración está determinada si conocemos las coordenadas x e y , así como las dos componentes de la velocidad v_x y v_y . En este caso, la dimensión del espacio es 4.

El número de coches que hay aparcados en un estacionamiento subterráneo solo depende de este número, por tanto el espacio de fases es sencillamente $\mathbb{N}$, en realidad un subconjunto de éste.

Una vez que conocemos el espacio de fases de un sistema el cual queremos estudiar, necesitamos una ley que nos de la evolución de éste en el espacio de fases. Podemos aquí diferenciar entre sistemas dinámicos discretos y continuos.

Donde los EEGs pertenecen a los discretos, para poder crear este espacio de fase tendremos que construirlo de la siguiente manera:

3.2.2 Sistemas dinámicos discretos

Estos son en los que la evolución del sistema se hace “a salto”, o siendo formales:

Definición 1 Sea $X \subset \mathbb{R}^n$ un conjunto no vacío. Sea $f: X \rightarrow X$ una función que relaciona estados mediante la expresión

$$x_{k+1} = f(x_k) \quad (1)$$

La pareja (f, X) es un sistema dinámico. Al conjunto X se le denomina espacio de fases del sistema.

Es decir, la ley que da la evolución, relaciona los puntos del espacio de fases de manera discreta. Si el sistema empieza en una configuración x_0 , tras k pasos se encontrará en el estado $f^k(x_0)$. A x_0 se le conoce como condición inicial y al conjunto

$$\{x_0, f(x_0), f^2(x_0), \dots\} \quad (2)$$

órbita de x_0

La principal característica de la Base de Datos (**BD**) es que: Surgen de un largo estudio para examinar correlaciones de **EEG**, en pacientes con predisposición genética al alcoholismo. Esta **BD** contiene mediciones desde 64 electrodos, puestos sobre cuero cabelludo del paciente, las cuales fueron muestreadas a 256Hz (3.9-m/s)¹.

Se consideraron 2 grupos de pacientes: Alcohólicos y de control. Cada paciente fue expuesto tanto a un estímulo simple ($S1$) o a dos estímulos ($S1$ y $S2$) los cuales fueron representados de pacientes seleccionados del conjunto descrito de 1980 de Snodgrass y Vanderwart⁴⁷. Cuando dos estímulos fueron mostrados, ellos fueron presentados en ya sea una condición acoplada donde $S1$ fue idéntica a $S2$ o en una condición no acoplada donde $S1$ difirió de $S2$. Las posiciones de los electrodos fueron localizados en sitios estándar, (Standard Electrode Position Nomenclature, American Electroencephalographic Association 1990).

En la actualidad, el análisis de las **ST** está basado en la teoría de los sistemas dinámicos (**TSD**), considerando que las **ST**, están en el espacio de estado (**ES**). Aprovechando la **TSD** que considera: usando una variable y sus derivadas, para trabajar en el espacio de fase, como la señal no es continua ni bien portada, no podemos usar las derivadas, por esta razón empleamos un método de **TSD**, retardos óptimos en una **ST**, la Teoría de la Información de Shannon⁴⁹⁻⁵¹, conocida como Información Mutua $I(s)$ 20 si tenemos dos registros $x(t)$ y $x(t+s)$ de una **ST** determinada, donde s es la separación entre ambos registros, se considera que hay cierta conexión entre ambas medidas. Para conocer el tamaño de esta conexión, en

función de la información que aportan los valores $x(t)$ y $x(t + s)$, disponemos de la siguiente expresión:

$$I(s) = \sum_{x(t), x(t+s)} P(x(t), x(t+s)) \log_2 \left[\frac{P(x(t), x(t+s))}{P(x(t))P(x(t+s))} \right] \quad (3)$$

Cuando $I(s)$ es relativamente grande, la información que $x(t + s)$ aporta al sistema, es redundante. Por este motivo se considera que el intervalo idóneo para la reconstrucción del atractor, es el valor de s más pequeño que podemos encontrar, Figura 3.5, este punto en la **ST** se hace lo más independiente posible, una de la otra, es decir, no redundantes; pudiéndose utilizar como ejes coordenados. Así que $x(t + s)$, $x(t + 2s)$, $x(t + 3s)$, ... son los ejes del espacio de fase. El atractor está formado por una serie de puntos o estados, representados en el espacio de fase con m dimensiones de la **ST**, que surgen de proyectar en este espacio los valores de las diferentes **ST**. Este atractor no es más que una serie de localizaciones, en este espacio de m dimensiones, que contienen mucha información de las características del sistema y que, por extensión, tienen una marcada influencia en la evolución a lo largo del tiempo de las diferentes variables interrelacionadas.




Figura 3.5 Resultados de la ecuación de la información mutua en un EEG.

Al aplicar la metodología a todos los datos obtuvimos lo siguiente:

Un cuerpo de datos con los valor de la información mutua, para cada electrodo de los 64, por cada paciente de los 97, obteniendo una matriz bidimensional de 97 X 64, ver Figura 3.6, que esquematiza claramente esta acción, de la reducción de la dimensionalidad de las matrices de datos.




Figura 3.6 Matriz con valores de la Información Mutua de los EEG.

Para encontrar la dimensión del atractor, es decir, una medida de su capacidad de ocupar espacio, en el espacio de fase, tenemos el algoritmo de la Dimensión de Correlación, requiere la reconstrucción del atractor a partir de la **ST** observada (los EEG) y sus corrimientos óptimos.

Una vez reconstruido el atractor, para distintos valores de m , tenemos que calcular la Integral de Correlación para cada uno de estos:

$$C(m + \varepsilon) = \frac{1}{N_{\text{pares}}} \sum_{j=m}^N \sum_{k < j-w} \theta(\varepsilon - (\delta_j - \delta_k)) \quad (4)$$

Donde δ_j , es el retardo del vector en m dimensiones, $N_{\text{pares}} = (N - m + 1)(N - m - w + 1)/2$; el número de pares de puntos que convergen por las sumas; θ es la función de peso Heaviside; w es lo suficientemente pequeño, y cuando la dimensión envolvente m excede la caja contenedora del atractor, calculamos nuevamente la dimensión de correlación, con una dimensión extra, $m + 1$, inicialmente no sabemos cual es la dimensión de correlación de la **ST**, por ello calculamos $m = 1, 2, 3, \dots$ al graficar los $\log(C(\varepsilon))$ y $\log(\varepsilon)$ debemos identificar una zona que al ajustar pequeñas rectas, en las diferentes curvas de los logaritmos, las rectas son paralelas, esta zona se llama: “zona de invarianza”, Para ajustar las rectas usamos regresión lineal. Con dos puntos trazamos una recta, con tres ajustamos una recta, por ello usamos los tres primeros puntos, recorriendo un punto cada vez hasta recorrer todos, al encontrar en las diferentes curvas de los logaritmos de m las pendientes, y estas son casi idénticas, en los mismos 3 puntos, esa es la zona de invarianza de escala.

Y las pendientes de estas rectas, en la zona de saturación, nos proporciona el valor de la dimensión de correlación, este valor al ser fraccionario se eleva al entero próximo (ejemplo $D_2 = 2.5202 \approx 3$ como en la Figura 3.7), teniendo ya la dimensión del atractor (D_2) y el τ óptimo, podemos graficarlo, en la Figura 3.7, vemos el proceso para obtener la forma del atractor y su dimensión.




Figura 3.7 Herramienta probada con datos teóricos de Lorenz.

Herramienta probada con datos teóricos (3er ecuación del sistema de Lorenz), en la parte superior izquierda, se muestra la gráfica de puntos de la 3er ecuación, en la parte superior derecha, el atractor del sistema, el tercer gráfico en la parte central, de color rojo muestra la zona de invarianza de escala, y en esa parte se le ajustan las rectas, el valor de las pendientes en la parte inferior izquierda, y la dimensión del atractor es mostrada en el gráfico de la parte inferior derecha. Al tener ya la dimensión de correlación de cada electrodo tenemos 64 valores o características (ver Figura 3.8) por paciente. El siguiente paso es calcular el testor típico.




Figura 3.8 Matriz con valores de la Dimensión de Correlación de los EEG.

3.3 Teoría Lógica Combinatoria

El concepto de testor aparece por primera vez en un trabajo de los científicos Rusos Chegus y Yablonskii en un intento por tratar de simplificar la tarea de encontrar desperfectos en circuitos eléctricos, que podían ser modelados a través de funciones del álgebra de la lógica. En 1966 un grupo de científicos rusos, al mando de Yu. I. Zhuravlev, dan un nuevo enfoque al concepto de testor que permite aplicaciones importantes vinculadas a los problemas de clasificación con aprendizaje y selección de variables. En esencia, un testor es un conjunto de características (rasgos) que diferencia a elementos (objetos) de clases distintas. Un testor típico es un testor al que si le eliminamos cualquiera de sus rasgos pierde la propiedad de ser testor⁵².

3.3.1 Fundamentos.

Para la solución de problemas de R.P. utilizando el enfoque lógico combinatorio⁵²⁻⁵⁶, la determinación de la función de semejanza desempeña un papel relevante. La función de semejanza es el dispositivo matemático que formaliza un criterio de analogía entre pares de objetos de un universo dado; es la manera en que se expresa, utilizando un lenguaje matemático, el procedimiento que siguen los especialistas al comparar un par de objetos de un universo y emitir un criterio acerca de su parecido o semejanza. Este procedimiento es esencial en el proceso de reconocimiento y está siempre permeado de una gran subjetividad.

Definamos:

Sea $U = \{O_1, \dots, O_m, \dots\}$ un universo finito o numerable de objetos. Sea $M = \{x_1, \dots, x_n\}$ el conjunto de rasgos a través de los cuales se describen los elementos de U , es decir, a cada elemento O_j de U le podemos asignar un n -uplo $I(O_j) = (x_1(O_j), \dots, x_n(O_j))$ que denominaremos descripción de O_j (Figura 3.9), M_p es el conjunto de valores admisibles del rasgo x_p , $p = 1, \dots, n$ (Figura 3.10), es decir, $x_p(O_s) \in M_p, s = 1, \dots, m, \dots$

En la Teoría de Reconocimiento de Patrones, el concepto de analogía es, sin lugar a dudas, uno de los más importantes.

Para muchos modeladores matemáticos, la semejanza entre dos objetos puede representarse por medio de una función de distancia, entre las respectivas descripciones de dichos objetos, ya que cercanía y semejanza pueden ser conceptos sinónimos. Esto no siempre es lo mejor, ya que, matemáticamente la distancia es una función real, simétrica y que cumple la desigualdad triangular. Como se muestra con las propiedades de: Igualdad, simetría y desigualdad triangular.

U =	$I(O) = (x_1(O), x_2(O), x_3(O), x_4(O))$				Clases
	O_1 (Ingeniero, 26, M, 1.75)				K_1 Buen Pagador
	O_2 (Médico, 33, F, 1.73)				
	O_3 (Abogado, 50, M, 1.62)				
	O_4 (Ingeniero, 48, M, 1.70)				
	O_5 (Abogado, 46, F, 1.55)				
	O_6 (Médico, 26, F, 1.61)				K_2 Mal Pagador
	O_7 (Médico, 30, F, 1.63)				
	O_8 (Abogado, 24, M, 1.79)				
	O_9 (Ingeniero, 26, M, 1.64)				

Figura 3.9 Matriz de Aprendizaje.

Se le llama Matriz de Aprendizaje (MA) al n-uplo que contiene las descripciones de los objetos.

donde:	$X_1(O_i) \in M_1 =$	{ Ingeniero, Médico, Abogado }	Profesión
	$X_2(O_i) \in M_2 =$	{ 22, 23, 24, ..., 54, 55 }	Edad
	$X_3(O_i) \in M_3 =$	{ M, F }	Sexo
	$X_4(O_i) \in M_4 =$	{ 1.50, 1.52, 1.53, ..., 1.79, 1.80 }	Estatura

Figura 3.10 Conjunto de valores admisibles al rasgo.

3.3.2 Criterios de comparación

Pudiera decirse que dos objetos “se parecen más mientras más cerca se encuentren sus descripciones” y con esto casi siempre se puede estar de acuerdo. Considérese el universo M de “objetos admisibles” y un cubrimiento $k_1, \dots, k_r$ de M por subconjuntos propios $k_i \subset M$, $i = 1, \dots, r$. Es decir, el conjunto M es la unión de los Subconjuntos $k_1, \dots, k_r$. Sea $R = \{x_1, \dots, x_n\}$, el conjunto de rasgos/variables en términos de los cuales se estudiarán los objetos admisibles. Cada rasgo x_i tiene asociado un conjunto M_i de valores admisibles del rasgo x_i , $i = 1, \dots, n$.

Este conjunto puede ser denominado también dominio de x_i

- ❖ Boléanos
- ❖ K-Valentes
- ❖ Reales
- ❖ Nominales

Se llama criterio de comparación de valores de la variable x_j a una función $C_j: M_j \times M_j \rightarrow L_j$, donde L_j es un conjunto totalmente ordenado, $j = 1, \dots, n$.

3.3.2.1 Creación de los criterios de comparación

A partir de las cualidades estadísticas de los datos, ya con la anomalía, se propone capturar un área de datos alrededor del promedio (ver Figura 3.16), variando sus límites superiores e inferiores, dependiendo la variabilidad de la característica y para garantizar la diferenciación de muestras en clases diferentes, usar un valor α , el cual se tendrá que calcular en un ciclo, que se verá más adelante, ya teniendo esta área se darán valores de cero si el valor está dentro del rango, si está fuera será de uno.

Nosotros tratamos de quitar un poco esa complejidad integrando las medidas estadísticas para lograr la creación de estos criterios de comparación de forma automática y sin recurrir a la pericia o buena fortuna del experto para su creación.

A continuación mostramos las fórmulas creadas para formar estos criterios de comparación:

$$\beta_{1i} = \left[\bar{A}_i - \frac{(\bar{A}_i - \min(\bar{A}_i))}{\alpha} \right] \quad (5)$$

$$\beta_{2i} = \left[\bar{A}_i + \frac{(\max(\bar{A}_i) - \bar{A}_i)}{\alpha} \right] \quad (6)$$

$$C_i(x_i(O_n), x_i(O_k)) = \begin{cases} 0 & \text{si } x_i(O_n), x_i(O_k) \in [\beta_{1i}, \beta_{2i}] \\ 1 & \text{en otro caso} \end{cases} \quad (7)$$

Dada una **MA** y $C_1, \dots, C_n$ criterios de comparación booleanos de cada uno de los rasgos, llamaremos Matriz de Diferencias de **MA**, y la denotaremos por **MD**, a la matriz booleana formada por las m filas. Nosotros planteamos aquí un paso intermedio para automatizar el proceso de los criterios de comparación, creando un corpus binario, denotado por δ y su forma de calcularlo será:

Definimos:

$\bar{A}$ La media del corpus de anomalías.

A El corpus de las anomalías.

β_{1i} El límite inferior alrededor del promedio.

β_{2i} El límite superior alrededor del promedio.

El operador de ajuste de los límites.

Algoritmo para calcular el Corpus binario δ :

1. Asignar valor de $\alpha=2$.
2. Asignar el valor máximo que puede tomar $\alpha = n$.
3. crear δ , usando las ecuaciones 5, 6 y 7

4. Si existen objetos (muestras) de diferente clase idénticos, incrementar valor de $\alpha = +1$, y si $\alpha < n$ regresar al paso 3.
5. Si no existen objetos (muestras) de diferente clase idénticos, ya tenemos un δ correcto (en caso contrario ver modificación en el Modelo Propuesto)

Para este trabajo, nosotros planteamos aquí las siguientes adecuaciones a los criterios de comparación, creando un δ y sus fórmulas serán las siguientes:

$$\beta_{MAX1i} = \left[\max(A_i) - \frac{(\max(A_i) - \text{std}(A_i))}{\alpha} \right] \quad (8)$$

$$\beta_{MAX2i} = [\max(A_i)] \quad (9)$$

$$\beta_{STD1i} = \left[\text{std}(A_i) - \frac{(\text{std}(A_i) - \bar{A}_i)}{\alpha} \right] \quad (10)$$

$$\beta_{STD2i} = \left[\text{std}(A_i) + \frac{(\max(A_i) - \text{std}(A_i))}{\alpha} \right] \quad (11)$$

$$\beta_{MEANi} = \left[\bar{A}_i - \frac{(\bar{A}_i - \min(A_i))}{\alpha} \right] \quad (12)$$

$$\beta_{MEAN2i} = \left[\bar{A}_i + \frac{(\text{std}(A_i) - \bar{A}_i)}{\alpha} \right] \quad (13)$$

$$\beta_{STD^{-1}1i} = \left[(\text{std}(A_i) - 1) - \frac{((\text{std}(A_i) - 1) - \bar{A}_i)}{\alpha} \right] \quad (14)$$

$$\beta_{STD^{-1}2i} = \left[(\text{std}(A_i) - 1) + \frac{(\max(A_i) - (\text{std}(A_i) - 1))}{\alpha} \right] \quad (15)$$

$$\beta_{MIN1i} = [\min(A_i)] \quad (16)$$

$$\beta_{MIN2i} = \left[\min(A_i) - \frac{(\bar{A}_i - \min(A_i))}{\alpha} \right] \quad (17)$$

$$\delta_{ji} = \begin{cases} 3 & \text{si } \beta_{MAX1i} \leq A_j \leq \beta_{MAX2i} \\ 1 & \text{e. o. c.} \end{cases} = C_i(x_i(O_n)) = \begin{cases} 3 & \text{si } x_i(O_n) \in [\beta_{MAX1i}, \beta_{MAX2i}] \\ 1 & \text{e. o. c.} \end{cases} \quad (18)$$

$$\delta_{ji} = \begin{cases} 2 & \text{si } \beta_{STD1i} \leq A_j \leq \beta_{STD2i} \\ 1 & \text{e. o. c.} \end{cases} = C_i(x_i(O_n)) = \begin{cases} 2 & \text{si } x_i(O_n) \in [\beta_{STD1i}, \beta_{STD2i}] \\ 1 & \text{e. o. c.} \end{cases} \quad (19)$$

$$\delta_{ji} = \begin{cases} 0 & \text{si } \beta_{MEAN1i} \leq A_j \leq \beta_{MEAN2i} \\ 1 & \text{e. o. c.} \end{cases} = C_i(x_i(O_n)) = \begin{cases} 0 & \text{si } x_i(O_n) \in [\beta_{MEAN1i}, \beta_{MEAN2i}] \\ 1 & \text{e. o. c.} \end{cases} \quad (20)$$

$$\delta_{ji} = \begin{cases} -1 & \text{si } \beta_{STD^{-1}1i} \leq A_j \leq \beta_{STD^{-1}2i} \\ 1 & \text{e. o. c.} \end{cases} = C_i(x_i(O_n)) = \begin{cases} -1 & \text{si } x_i(O_n) \in [\beta_{STD^{-1}1i}, \beta_{STD^{-1}2i}] \\ 1 & \text{e. o. c.} \end{cases} \quad (21)$$

$$\delta_{ji} = \begin{cases} -2 & \text{si } \beta_{MIN1i} \leq A_j \leq \beta_{MIN2i} \\ 1 & \text{e. o. c.} \end{cases} = C_i(x_i(O_n)) = \begin{cases} -2 & \text{si } x_i(O_n) \in [\beta_{MIN1i}, \beta_{MIN2i}] \\ 1 & \text{e. o. c.} \end{cases} \quad (22)$$

Resumiendo:

$$\delta_{ji} = \begin{cases} 3 & \text{si } \beta_{MAX1i} \leq A_j \leq \beta_{MAX2i} \\ 1 & \text{e. o. c.} \\ 2 & \text{si } \beta_{STD1i} \leq A_j \leq \beta_{STD2i} \\ 0 & \text{si } \beta_{MEAN1i} \leq A_j \leq \beta_{MEAN2i} \\ -1 & \text{si } \beta_{STD^{-1}1i} \leq A_j \leq \beta_{STD^{-1}2i} \\ -2 & \text{si } \beta_{MIN1i} \leq A_j \leq \beta_{MIN2i} \end{cases} \quad (23)$$




Figura 3.11 Representación de los criterios de comparación.

Las fórmulas y algoritmo anteriores, agrupan los valores de cada característica en unas bandas especiales (ver Figura 3.11 para el caso de las flores de IRIS). Estas bandas agrupan

zonas de similitud entre características, ya que el siguiente paso es calcular la matriz de diferencias, usando los criterios de comparación, con el δ_{ij} sólo comparamos si son valores iguales, asignamos un 0 y 1 si son diferentes, como se ve en la siguiente Figura.




Figura 3.12 Creación de la MD usando δ

3.3.3 Creación de la Matriz Básica (MB)

En este paso, se trata de reducir el tamaño de la MD, ya que al crearla su tamaño puede ser exponencial⁵³, por ello definimos:

Sea P y T dos renglones de MD. Diremos que P es subfila de T si:

$$\forall_j (a_{pj} = 1 \Rightarrow a_{tj} = 1) \text{ en todas las columnas donde P tiene un 1, T también} \quad (24)$$

$$\exists k (a_{tk} = 1 \wedge a_{pk} = 0) \text{ existe al menos una columna en la que T tiene un 1 y P no} \quad (25)$$

Ejemplo:




Figura 3.13 Creación de la MB, usando la MD

3.3.4 Cálculo del Testor Típico.

Como algoritmo de escala exterior, BT^{52-57} basa su funcionamiento en los siguientes elementos: una caracterización conveniente del concepto de testor y de testor típico, un orden definido sobre el conjunto potencia del conjunto de todos los rasgos (R), ver Figura 14.

Para la descripción del algoritmo, se utilizará un n -uplo booleano $\alpha = (\alpha_1, \dots, \alpha_n)$, tal que si $\alpha_j = 1$, esto indicará que la columna j aparece en el conjunto de columnas a considerar y $\alpha_j = 0$ significa lo contrario. Cada uno de estos n -uplos representa el llamado vector característico del subconjunto correspondiente de R .

Para encontrar la familia de testores típicos en un problema de clasificación supervisada, utilizaremos la matriz básica (**MB**) asociada al problema, la cual contiene la información mínima necesaria para encontrar los testores típicos.

Tomemos en cuenta las siguientes 3 proposiciones:

Proposición 1: El n-uplo $\alpha = (\alpha_1, \dots, \alpha_n)$ se llamará lista testor, si para toda fila $a = (a_1, \dots, a_n)$ de MB, se cumple que:

$$\forall (\alpha_i \wedge a_i) \neq 0, i = 1, \dots, n \quad (26)$$

$\alpha = (\alpha_1, \dots, \alpha_n)$ representa un testor típico (sabiendo que es lista testor), si para cada j tal que $\alpha_j = 1$, existe alguna fila en **MB** tal que su única coordenada unitaria coincidente con una coordenada no nula de α es la j -ésima. En este caso α se llamará lista testor típico.

Proposición 2 (dar salto ante testor): Sea $\alpha = (\alpha_1, \dots, \alpha_k, \dots, \alpha_n)$ un n-uplo lista testor(típico), y sea α_k la última coordenada unitaria (el uno más a la derecha) de α . Entonces los siguientes $2^{n-k} - 1$ n-uplos (en el orden establecido) se corresponden con testores no típicos.

Proposición 3 (dar salto ante no testor): Sea $\alpha = (\alpha_1, \dots, \alpha_n)$ un n-uplo correspondiente con un no lista testor, y sea $a = (a_1, \dots, a_n)$ una fila de MB tal que $\forall (\alpha_i \wedge a_i) = 0, i = 1, \dots, n$. Sea a la última coordenada unitaria de a (el uno más a la derecha), y sea $\alpha' = (\alpha'_1, \dots, \alpha'_n)$ tal que :

$$\alpha'_j = \begin{cases} \alpha_j & \text{si } j < u \\ 1 & \text{si } j = u \\ 0 & \text{si } j > u \end{cases} \quad (27)$$

Se muestra una versión del algoritmo **BT** original a continuación.

Paso 1: Se toma $\alpha = (0, 0, \dots, 0, 1)$

Paso 2: Si $\alpha > 2^n - 1$ ir al paso 4, en caso contrario, verificar Proposición 1 si α es lista testor y si es testor típico, lo guardamos.

Paso 3: a) Si α es lista testor (típico), generar $\alpha' = \alpha + 2^{n-k}$ (siendo k la posición del uno más a la derecha en α , verificando la Proposición 2).

b) Si α no es lista testor, generar α' (como en la proposición 3), tomando de entre las filas responsables de que α no sea testor, aquella cuyo último uno (el más a la derecha) aparezca más a la izquierda.

c) Tomar $\alpha = \alpha'$ e ir al paso 2.

Paso 4: Imprimir la lista de testores típicos. Fin.




Figura 3.14 Aplicación del algoritmo BT.

3.5 Redes Neuronales Artificiales

Las Redes Neuronales Artificiales, fueron originalmente una simulación abstracta de los sistemas nerviosos biológicos, formado de un conjunto de unidades llamadas “neuronas o nodos”, conectadas unas con otras. Estas conexiones tienen una gran semejanza con las dendritas y axones de un sistema nervioso biológico.

1943 - Warren McCulloch y Warren McCulloch, los primeros teóricos que concibieron los fundamentos de la computación neuronal, lanzaron una teoría acerca de la forma de trabajar de las neuronas. Ellos modelaron una red neuronal simple mediante circuitos eléctricos⁵⁸⁻⁶⁰.

3.5.1 La red incremental RCE

La red incremental **RCE** (restricted coulomb energy)⁶¹⁻⁶⁴, se puede ver también como una red feedforward de tres capas (Figura 3.15), desde el punto de vista neuronal. Las capas de entrada tienen los patrones (vectores) de entrada binarios.




Figura 3.15 Arquitectura de la red RCE.

El algoritmo de aprendizaje de la red **RCE** es:

1. Asigne el radio máximo $R_{\max}$ de las hiperesferas.
2. Asigne uno a la primera neurona oculta, y ponga su vector de pesos, para ser igual al primer vector de entrada del conjunto de entrenamiento ($w_1 = x_1$), y su radio $R_{\max}$ (centro de radio de la primera hiperesfera). Conecte la salida de esta neurona oculta (con el peso $v_{11} = 1$) a la neurona de salida, que representa la clase de salida y 1. Blanquear una variable modificar ($\text{mod} := \text{False}$), y colocar un puntero al segundo vector del conjunto de entrenamiento.
3. calcule la distancia de Hamming, entre el vector de entrada actual x_m y los centros de todas las hiperesferas (w_j pesos); si alguna distancia son menores o iguales al

radio ($d_{j^*} \leq R_{j^*}$), las neuronas ocultas correspondientes llegan a estar activas. Las siguientes tres situaciones pueden ocurrir:

- a) Todas las neuronas ocultas activas representan una (sub) categoría del vector de entrada actual (Nada se hace en este caso). Ir al paso 4.
 - b) Algunas de las neuronas ocultas activas pertenecen a la misma clase como entrada actual, pero las otras pertenecen a la(s) otra(s) clase(s). Reduzca los radios de todas las neuronas ocultas activas (hiperesferas), que están asociadas con clases incorrectas hasta que lleguen a estar inactivas; ponga la variable modificar ($mod:=True$).
 - c) La neurona oculta no está activa. Asigne una neurona oculta nueva con el vector de pesos $w_{jnew} = x_m$ y con un radio máximo R_{max} (centro y radio de la hiperesfera). Conecte su salida (con peso $v_{ijnew} = 1$) a la nueva neurona de salida correspondiente i (eso representa la clase y_m). Ponga la variable modificar ($mod:=True$).
4. Sí el próximo vector de la entrada en el conjunto de entrenamiento existe, colocar un puntero a este vector e ir al paso 3.
 5. Sí $mod:=False$, entonces parar el proceso de aprendizaje, sino colocar un puntero al primer vector de entrada del conjunto de entrenamiento, blanquear la variable modificar ($mod:=False$), e ir al paso 3.

Para esta tesis usamos la siguiente métrica, en lugar de la distancia de Hamming.

$$\sqrt{\frac{(\sum_{i=1}^n x_i - y_i)^2}{(\sum_{i=1}^n x_i)^2 - (\sum_{i=1}^n y_i)^2}} \quad (28)$$

Capítulo IV Resultados y Discusión

En este capítulo mostraremos los resultados obtenidos a lo largo de la investigación, desde los primeros resultados preliminares, que fueron muy alentadores hasta la culminación de este trabajo.

4.1 Resultados preliminares con la D_2

Los resultados obtenidos de forma preliminar fueron alentadores ya que sólo calculamos la dimensión de correlación, logrando obtener en una sola derivación (un solo electrodo elegido) la separación suficiente para clasificar las dos clases de muestras, éstas fueron seleccionadas al azar ya que contábamos con 5 pacientes de EEG-A y 5 de EEG-C, como se muestra en la figura siguiente:




Figura 4.1. Valores de D_2 para las 64 derivaciones.

En la Figura 4.1 presentamos con cruces (+) a EEG-C y con los asteriscos (*) EEG-A; el recuadro en el extremo derecho, que corresponde a la derivación 44 (electrodo en la posición F2), muestra que se separó mejor los dos grupos, uno con valores relativamente mayores, a 1.4 y el otro menores al umbral indicado de los valores de la dimensión del atractor.

En la derivación **F2**, obtuvimos los siguientes valores para la **D₂**:

Alcohólicos	Mutual	Autocorrelación	D ₂	Controlados	Mutual	Autocorrelación	D ₂
1	13	14	1.20265	1	19	40	1.41953
2	16	1	1.32946	2	16	17	1.60381
3	12	16	1.19126	3	17	15	1.60499
4	14	14	1.38173	4	21	22	1.51323
5	9	16	1.34469	5	23	34	1.64787
Media	12.8	12.2	1.28996	Media	19.2	25.6	1.55789

Tabla 4.1 resultados preliminares de **D₂**.




Figura 4.2. Ubicación del electrodo **F2** en las 64 derivaciones.

Desde un punto de vista gráfico, también se observaba una separación en las categorías **EEG-C** y **EEG-A**. Para hacer más evidentes los resultados emigraremos a **3D**.




Figura 4.3. Gráficas de punto, dimensión de atractor en 2D y 3D, con delay $\tau = 13, 16, 12, 14$ y 9 .

En la columna izquierda de la Figura 4.3, están los datos muestreados de los 5 EEG-A, mostrando la derivación, en el eje vertical, los 256 valores correspondientes a 1s de muestra, en el eje horizontal y en el título el código de la persona; en la columna central, en 2D los gráficos muestran su dimensión del atractor y con una cercanía muy marcada al valor del origen, para este grupo; en la tercera columna observamos la dinámica del sistema en estudio graficada en 3D, conservando las características de estar cercano al origen y seguir compacto.




Figura 4.4. Gráficas de punto, dimensión de atractor en 2D y 3D, con delay $\tau = 19, 16, 17, 21$ y 23 .

Igual que en la Figura 4.3 anterior, la Figura 4.4 de EEG-C de personas controladas; la columna central muestra la evolución dinámica de los EEG, o atractor en 2D, en este grupo aparece con una forma irregular, perpendicular al eje horizontal con una ligera inclinación a la izquierda en forma descendente; en la tercera columna observamos el atractor en 3D, conservando características de no estar cercano al origen en los tres ejes y tener una forma irregular, pero mejor definida.

4.2 Resultados finales con D_2

Como mostramos en el tema anterior, la D_2 es una gran herramienta para diferenciar muestras de diferentes clases de pacientes, al integrar los 97, encontramos

que era difícil encontrar una sola característica que nos discriminara las dos clases de muestras, ya que en el cerebro no solo se reflejan problemas del alcoholismo, por ello fue necesario incorporar más electrodos para hacer dicha clasificación, usando los datos originales, restándoles el promedio, el corpus binario y para validar el Análisis de componentes principales (PCA Principal Components Analysis)^{56,65-67}.

Variables seleccionadas por el testor: 8

Testor creado= 1 2 3 6 9 11 12 17

Al hacer el reconocimiento con la red neuronal RCE, haciendo grupos de validación, corriéndolo 10 veces, para 2, 3, 4 y 5 grupos obtuvimos los siguientes gráficos:




Figura 4.5 Gráficas del reconocimiento con la D_2

En la Figura 4.5 podemos observar los datos del extremo superior izquierdo, mostrando los datos en el eje horizontal, de los grupos de la validación cruzada, en eje vertical el porcentaje de reconocimiento con la red RCE, usando la D_2 , sin modificar, En el extremo derecho los datos de la Anomalía de la D_2 , en extremo inferior izquierdo, los datos transformados con el δ que llamamos Xbin, y en el extremo derecho, los datos del PCA aplicado a los originales, También observamos que entra

más grupos, es fácil reconocerlos, pero el Xbin sobresale de todos ya que rápidamente se ubica en los alrededores del 85% al 90% de reconocimiento.

4.3 Resultados finales con Información Mutua

La información mutua es un paso antes del cálculo de la D_2 , pero también contiene información importante, por ello el 3er experimento que hicimos seleccionamos esta característica. Al aplicarle lo mismo que al experimento del tema 4.2 obtuvimos esta gráfico.




Figura 4.6. Gráficas del reconocimiento con la información mutua.

En la Figura 4.6 podemos observar los datos del extremo superior izquierdo, mostrando los datos en el eje horizontal, de los grupos de la validación cruzada, en eje vertical el porcentaje de reconocimiento con la red **RCE**, usando la Información mutua, sin modificar, En el extremo derecho los datos de la Anomalia de la Información mutua, en extremo inferior izquierdo, los datos transformados con el δ que llamamos Xbin, y en el extremo derecho, los datos del **PCA** aplicado a los originales, También observamos que entra más grupos, es fácil reconocerlos, pero el **Xbin** sobresale de

todos ya que rápidamente se ubica en los alrededores del 85% al 95% de reconocimiento al igual que el de las Anomalías.

Capítulo V Conclusiones

En este capítulo discutiremos las hipótesis planteadas al inicio, con base en los resultados obtenidos a lo largo de la investigación, hasta la culminación de este trabajo, planteando algunos trabajos futuros.

5.1 Conclusiones

Al hacer la comparación de las características constatamos que cada tipo de característica tiene sus peculiaridades, pero tanto la D_2 y la información mutua, son de gran utilidad, si observamos los 3 experimentos numéricos encontramos que con ambas características podemos hacer una clasificación y que ambas son fundamentales para poder caracterizar las señales de los EEG.

Los EEG, fueron caracterizados y clasificados de forma exitosa, ya que el porcentaje de clasificación fue mayor al 80% y en algunos casos alcanzamos más del 95%

La Primer Hipótesis dice:

El uso de la metodología Dimensión de Correlación (D_2) no lineal permitirá la clasificación de EEGs para diferenciar entre Electroencefalogramas de Pacientes Alcohólicos (EEG-A) y Electroencefalogramas de Pacientes Controlados (EEG-C) con una confianza mayor al 85% en todos los casos.

Observamos en la Figura 4.5, los datos graficados y podemos decir que los cuerpos de datos creados, para estas pruebas, nos arrojaron valores aceptables. En el caso de la validación cruzada para 4 y 5 grupos alcanzamos y rebasamos la medición pedida ya que en los datos de **Xbin** encontramos los valores mínimos de 87.5% y 91.0% (las

tablas de valores están en el **Anexo C**), respectivamente. Siendo este cuerpo de datos el que mejores resultados mostró, por encima de la metodología del **PCA**.

La Segunda Hipótesis dice:

El uso de la metodología Lógica combinatoria (LC) permitirá la clasificación de EEGs para diferenciar entre EEG-A y EEG-C con número reducido de puntos de medida, manteniendo la confianza mayor al 85% en todos los casos.

Esta metodología nos permitió también crear el cuerpo de datos **Xbin** (δ) para hacer el reconocimiento de patrones con la red **RCE**, Usamos dos cuerpos de datos iniciales:

D_2

Información Mutua

Lo puntos de medida seleccionados para cada uno fueron:

Para **D_2** 8 variables seleccionadas por el testor: = {1, 2, 3, 6, 9, 11, 12, 17}

Para ***Información Mutua*** 7 variables seleccionadas por el testor: = {2, 3, 4, 5, 13, 14, 24}

Se logró reducir los datos de un total de 64 puntos de medida, a 8 y 7, es decir, se redujo en un 87% el tamaño de los datos.

Obteniendo además un porcentaje de clasificación mayor al planteado inicialmente, El **PCA** se ajustó con los parámetros para tener el mismo número de características y observamos una pequeña mejoría para los datos tratados con la anomalía y el **Xbin**.

La Tercer Hipótesis dice:

El uso de la metodología LC permitirá la clasificación de EEGs para diferenciar entre EEG-A y EEG-C con igual o mayor porcentaje de reconocimiento que metodologías establecidas como lo es el **PCA**.

Como se muestra en las Figuras 4.5 y 4.6, para la D_2 el X_{bin} es superior a los demás incluido el PCA , para los datos calculando el **mutual** (información mutua), las anomalías tienen una ligera ventaja sobre el PCA , ya que rápidamente se encuentra en los rangos del 90% y 95%, este último cuerpo de datos es la base para calcular la D_2 , además que tiene mayores porcentajes de reconocimiento.

El PCA al igual que la LC , reducen la dimensión de muestras, facilitando el reconocimiento o clasificación de los datos, la diferencia fundamental entre ambas metodologías radica en que el PCA , trabaja con toda la matriz de datos y cada vez que agregue datos, ésta se tendrá que calcular, la LC , trabaja con los datos y solo se calcula 1 sola vez, ya que nos muestra las características importantes sin hacerles transformaciones.

Con base a los datos obtenidos y los experimentos realizados, podemos afirmar que la metodología aplicada en este trabajo y los desarrollos alcanzados en el mismo, fueron exitosos, al lograr reducir los datos y alcanzar un porcentaje de clasificación superior al 85%.

5.2 Trabajos futuros

En los trabajos posteriores incorporaremos más características, como los exponentes de Lyapunov, medidas de complejidad, cálculo de leyes de potencia, etc, estas características no lineales nos pueden vislumbrar nuevas y mejores formas de caracterizar diferentes padecimientos neuronales.

También probaremos otros algoritmos de clasificación y extracción de características probando si la LC sigue siendo robusta o existe algún método que lo supere y nos permita mejorar los resultados alcanzados en este trabajo

Anexo A Descomprimir los EEG




Figura Anexo-A.1 Archivo completo de EEG para descomprimir.




Figura Anexo-A.2 Archivo completo de EEG opciones para descomprimir.




Figura Anexo-A.3 Descomprimiendo archivo completo de EEG.




Figura Anexo-A.4 Todos los archivo de EEG.

Anexo B Código fuente de GWBASIC

Código para reconstruir una serie de tiempo con la FFT a partir de N armónicos

```

C:\DOCUIME-1\ALFONSO-1\Desktop\WG1\GWBASIC.EXE

--> FOURIER ANALYSIS <--

Input File (Q=Quit, <CR>=): ee.dat

C:\DOCUIME-1\ALFONSO-1\Desktop\WG1\GWBASIC.EXE

--> FOURIER ANALYSIS <--

Input File (Q=Quit, <CR>=): ee.dat
1 Data Field(s)
1 File Columns in ee.dat

Determining Array Size.....
# of Data Points: 20      Max # of Harmonic Pairs: 9
# of Harmonic Pairs? 1

C:\DOCUIME-1\ALFONSO-1\Desktop\WG1\GWBASIC.EXE

--> FOURIER ANALYSIS <--

Input File (Q=Quit, <CR>=): ee.dat
1 Data Field(s)
1 File Columns in ee.dat

Determining Array Size.....
# of Data Points: 20      Max # of Harmonic Pairs: 9
# of Harmonic Pairs? 1

Reading data.....
Working...

Output: S(screen), P(print), F(file), or Q(quit)? S

C:\DOCUIME-1\ALFONSO-1\Desktop\WG1\GWBASIC.EXE

I      O(I) COEFF      B(I) COEFF
0      1.247423      0
1      .038966      -.5055101E-02

Continue or Quit (C,Q)? -

C:\DOCUIME-1\ALFONSO-1\Desktop\WG1\GWBASIC.EXE

I      ORIG X(I)      CALC X(I)      DIFFERENCE
0      .95013      .6526726      .2874524
1      .23114      .6420593      -.4109193
2      .68684      .6196448      -.1280481E-02
3      -.48598      .5976286      -.1116485
4      .8913      .5701555      .3131346
5      .7621      .5631607      .1989393
6      .45647      .5540831      -.9761309E-02
7      .818504      .5518213      -.5351172
8      .82141      .5565965      .2648136
9      .4447      .5679414      -.1232414
10      .61543      .5847455      .3488451E-02
11      .79194      .6051639      .1865761
12      .92181      .6277263      .2948317
13      .73821      .6497746      .8441544E-02
14      .19297      .6692578      -.4929978
15      .40671      .6842625      -.2985525
16      .93547      .6933482      .2421298
17      .9169      .6956021      .2212779

Continue or Quit (C,Q)?
LIST 2000 3000 4000 5000 6000 7000 8000

```

Figura Anexo-B.4 Ejemplo de GWBASIC.

```

0'16 Sep 83 -> V3.0
1 SPNAM$="FOURIER"
75'
80' COPYRIGHT (C) 1983, NORTHWEST ANALYTICAL - PORTLAND, OR
97'
98' ----- PREFACE.ASP ----- [99-300] 10 Aug 83: chg 2 A-Z std
99 DEFINIT A-Z: ON ERROR GOTO 9000
100 COMMON BLS,FFS,ERHS,CS$,INVID$,UNVID$,IFIL$,ROCS,RDAT$
200 COLS=1
220 PI21=3.141591*2
2998' >>----- INPUT SECTION -----<< (3000-3995)
2999 CLS
3000 PRINT CS$
3020 PRINT TAB(13) INVID$--> FOURIER ANALYSIS <--UNVID$: PRINT: PRINT

```

```

3100 GOSUB 3900
3120 PRINT: PRINT "Determining Array Size.";
3140 WHILE+ NOT EOF(1): GOSUB 3800: WEND: NP=ROWS
3160 PRINT: PRINT
3180 MXHP=NP\2-1
3200 PRINT " # of Data Points: "NP" Max # of Harmonic Pairs: "MXHP
3220 INPUT " # of Harmonic Pairs: "NHP
3240 IF NHP>MXHP THEN PRINT BLS: GOTO 3200
3260 DIM X(NP),ACF(NHP),BCF(NHP)
3280 PRINT: PRINT "Reading data.";
3300 CLOSE: OPEN "I",I,IFIL$: ROWS=0: IEND=0
3340 FOR I=1 TO NP: GOSUB 3800: X(I)=COL(1): NEXT
3380 PRINT: PRINT
3390 GOTO 4000
3797 ' INSTUFF.ASP - 13 Oct 83 - 3924:3910->3900; 3910...+Q=Xit prompt
3798' ===<GET ROW>=== (3800-3900)
3799' IN:HICOL,ICOLS,SEL(),ROWS,ROCS,ROC(),TIN: OUT:ROWS+1,COL(),IEND
3800 PRINT: ";
3805 IF IEND THEN RETURN "reset b4 re-read!!!
3810 IF ROCS="ROW" THEN 3850
3815'
3820 FOR COL=1 TO HICOL: INPUT #1,TIN(1,COL):NEXT "Col read
3830 IF HICOL<ICOLS THEN LINE INPUT #1,GIS
3835 FOR COL=1 TO COLS:COL(COL)=TIN(1,SEL(COL)):NEXT
3840 ROWS=ROWS+1
3845 IF EOF(1) THEN 3890:ELSE RETURN
3847'
3850 ROWS=ROWS+1 'Row read
3870 FOR COL=1 TO COLS:COL(COL)=ROC(1,COL,ROWS):NEXT
3880 IF ROWS<ICOLS THEN RETURN
3887'
3890 IEND=-1: RETURN
3897'
3898' ===<INPARAMSET>=== (3900-4000)
3899' IN:COLS,IFIL$,ROCS OUT:ICOLS,HICOL,SEL(),IEND,ROC(),
3900 ROWS=0: HICOL=0: ICOLS=0: IEND=0
3910 PRINT "Input File (Q=Quit, <CR>="IFIL$; LINE INPUT "): ";IS
3913 IF IS="" THEN IF INSTR("Qq",IS) THEN 8400:ELSE IFIL$=IS
3915 IF IFIL$="" THEN 3910
3917 CLOSE 1: OPEN "I",I,IFIL$
3918 IF EOF(1) THEN PRINT ERHS"FILE EMPTY":GOTO 3900
3919 PRINT COLS"Data Field(s)"
3920 LINE INPUT #1,IS: L=LEN(IS): F=0 'Ascertain #of File Cols
3921 FOR I=1 TO L
3922 IF INSTR(" ",MID$(IS,I,1)) THEN F=0:ELSE IF F=0 THEN F=1:ICOLS=ICOLS+1
3923 NEXT: IF ROCS="ROW" THEN 3925:ELSE PRINT ICOLS"File Columns in
"IFIL$
3924 IF ICOLS<COLS THEN PRINT ERHS"NOT ENOUGH COLS":GOTO 3900:ELSE
3926
3925 PRINT INVID$"ROW Mode"UNVID$
3926 DIM COL(COLS),SEL(COLS) 'erase b4 re-call!!!
3927 CLOSE 1: OPEN "I",I,IFIL$
3928 IF ICOLS=1 AND ROCS<="ROW" THEN IS="1 ": GOTO 3931
3929 LINE INPUT "Field Assignment(s) (<CR>=1:1): ";IS
3930 IF IS="" THEN 3960:ELSE IS=IS+" "
3931 FOR COL=1 TO COLS 'Parse Usage String
3932 C=INSTR(IS," "); TS=VAL(LEFT$(IS,C)): IS=MID$(IS,C+1)
3933 IF TS<1 OR (TS=ICOLS AND ROCS<="ROW") THEN COL=COLS+9:GOTO 3940
3934 SEL(COL)=TS
3939 IF TS>HICOL THEN HICOL=TS
3940 NEXT
3945 IF COL>COLS+3 THEN PRINT ERHS"BAD FIELD VALUE OR COUNT":GOTO
3929
3950 IF ROCS="ROW" THEN 3965:ELSE DIM TIN(HICOL) 'era b4 recall if
Colmode!!!
3955 RETURN
3957'
3960 FOR COL=1 TO COLS:SEL(COL)=COL:NEXT 'Gen deflt (1=1,2=2,...) Sel's
3962 HICOL=COLS
3963 GOTO 3950
3964'
3965 DIM ROC(1,COLS,ICOLS) 'era b4 recall if RowMode!!!

```

```

3970 WHILE+ (NOT EOF(1) AND (NOT IEND)): ROWS=ROWS+1 'Pre-read Sel'd
Rows
3988 WEND
3972 FOR R=1 TO COLS
3974 IF ROWS=SEL(R) THEN SEL(R)=SEL(R):C=R:R=COLS+9
3976 NEXT: IF R>COLS+3 THEN 3980
3978 LINE INPUT #1,GIS: GOTO 3988
3980 FOR I=1 TO ICOLS:INPUT#1,ROC(C,I):NEXT
3982 FOR R=1 TO COLS
3983 IF SEL(R)>0 THEN R=COLS+9
3984 NEXT: IF R<COLS+3 THEN IEND=-1
3990 IF IEND=0 THEN PRINT ERHS"NOT ENOUGH ROWS - EXITING":GOTO 8400
3992 IEND=0: ROWS=0
3993 FOR C=1 TO COLS:SEL(C)=SEL(C):NEXT
3995 RETURN
3998 '>-----> MAIN ALGORITHM SECTION <-----< (4000-5995)
4000 PRINT "Working..."
4040 FOR H=0 TO NHP: FOR R=1 TO NP
4050 KI=PI2/H*(R-1)/NP
4060 ACF(H)=ACF(H)+X(R)*COS(KI)
4070 BCF(H)=BCF(H)+X(R)*SIN(KI)
4080 NEXT R
4100 ACF(H)=ACF(H)*2/NP
4110 BCF(H)=BCF(H)*2/NP
4120 NEXT H
5998 '>-----> OUTPUT SECTION <-----< (6000-6995)
6000 PRINT
6020 HD$=" I A(I) COEFF B(I) COEFF"
6030 H2$="-----"
6040 T1=16: T2=31: T3=46
6100 PRINT: GOSUB 6900
6110 IF MO=3 THEN PRINT:PRINT"Writing coefficient file...";
6120 FOR H=0 TO NHP: GOSUB 6700: IF CQ THEN H=NHP: GOTO 6190
6130 ON MO GOTO 6150,6160,6170
6150 PRINT "H:TAB(T1)ACF(H):TAB(T2)BCF(H): GOTO 6190
6160 LPRINT "H:TAB(T1)ACF(H):TAB(T2)BCF(H): GOTO 6190
6170 PRINT #2,H:ACF(H):BCF(H)
6190 NEXT H
6200 '
6220 HD$=" I ORIG X(I) CALC X(I) DIFFERENCE"
6230 H2$="-----"
6240 LC= ML-1
6250 IF MO<>3 THEN 6260 :ELSE PRINT: PRINT
6252 PRINT "Observed & Calculated X File -":GOSUB 6930
6260 FOR R=1 TO NP: GOSUB 6700: IF CQ THEN R=NP: GOTO 6400
6270 YI=0
6280 FOR H=1 TO NHP
6290 KI=PI2/H*(R-1)/NP
6300 YI=YI+ACF(H)*COS(KI)+BCF(H)*SIN(KI)
6320 NEXT H
6330 YI=YI+ACF(0)/2
6350 ON MO GOTO 6360,6370,6380
6360 PRINT "R-1:TAB(T1)X(R):TAB(T2)YI:TAB(T3)X(R)-YI: GOTO 6400
6370 LPRINT "R-1:TAB(T1)X(R):TAB(T2)YI:TAB(T3)X(R)-YI: GOTO 6400
6380 PRINT #2,R-1:X(R):YI:X(R)-YI
6400 NEXT R
6500 GOTO 6000
6697 '
6698 '----<PAGOUT.ASP>--- 24 Aug 83: don't print null IFIL$
6700 IF MO=3 THEN RETURN
6710 IF PH$="" THEN PH$="--> PROG:"+SPNAM$:ELSE 6720
6713 IF IFIL$<>"" THEN PH$=PH$+" FILE:"+IFIL$
6716 IF RDAT$<>"" THEN PH$=PH$+" DATE:"+RDAT$
6720 IF ML THEN 6740 :ELSE LC=0
6721 IF MO=1 THEN ML=18: GOTO 6820
6722 ML=53: PG=1
6724 PRINT: PRINT"--> MAKE PRINTER READY"
6726 LINE INPUT "Report ID: ";Z$
6727 IF Z$<>"" THEN PH$=PH$+" ID: "+Z$
6728 GOTO 6855
6740 LC= LC+1: IF (LC MOD ML) THEN RETURN
6760 IF MO=2 THEN 6850
6780 PRINT: LINE INPUT "Continue or Quit (C,Q)? ";I$
6800 IF INSTR(" Qq",LEFT$(I$,1))>1 THEN CQ=-1: RETURN :ELSE CQ=0
6820 CLS
6830 PRINT CSS: PRINT HD$: PRINT H2$: PRINT
6840 RETURN
6848 '
6850 LPRINT FF$:
6855 LPRINT: LPRINT PH$:TAB(66)"PAGE ";PG: LPRINT
6860 LPRINT HD$: LPRINT H2$: LPRINT
6870 PG=PG+1
6880 RETURN
6897 '
6898 '----<SETOUT.ASP>---8/24/83: chg prompts,xit;-Defst ofl
6899 ' OUT:MO,ML,CQ,PH$
6900 PRINT INVID$"Output"UNVID$:
6905 LINE INPUT": S(screen), P(rinter), F(file), or Q(uit)? ";I$
6910 MO=INSTR(" SsPpFfQq",LEFT$(I$,1))
6911 IF MO<2 THEN 6900 :ELSE MO=MO\2 '1=Scrn;2=LP;3=File;4=EXIT
6912 IF MO=4 THEN IF LEN(I$)=1 THEN 8400 :ELSE 8500 '---> XITOR
6915 ML=0: CQ=0: PH$=""
6920 IF MO<>3 THEN RETURN
6930 LINE INPUT "Output File Name: ";OFIL$
6935 IF OFIL$="" THEN 6930
6950 CLOSE 2: OPEN "I",2,OFIL$
6960 PRINT OFIL$ exists: re-use it (Y,N)? "; LINE INPUT I$
6970 I=INSTR(" YyNn",LEFT$(I$,1))
6972 IF I<2 THEN 6960 :ELSE IF I>3 THEN 6930
6977 CLOSE 2: OPEN "O",2,OFIL$
6980 RETURN
8397 ' XITOR.ASP - 10/17/83 - +mucho disk err traps; elim ->BASIC
8398 ' ---> GET XIT COMM
8400 LINE INPUT "Exit Command: <CR>=SP, R(erun), S(ystem), or PROGRAM -- ";I$
8420 I$="Q"+I$
8498 ' ---> PROCESS XIT COMM --->
8500 I$=MID$(I$,2)
8510 IF I$="" THEN I$="SP"
8520 WHILE+ LEFT$(I$,1)="-" : I$=MID$(I$,2): WEND
8530 I=INSTR(I$," ")
8540 IF I THEN I$=LEFT$(I$,I-1):IRS=MID$(I$,I+1):ELSE ILS=I$:IRS=""
8550 IF INSTR("SS",ILS) THEN SYSTEM
8560 IF IRS<>"" THEN IFIL$=OFIL$
8565 CLOSE "Anything dat mite b opn
8570 IF INSTR("Rr",ILS) THEN CHAIN SPNAM$:ELSE CHAIN ILS
8997 '
8998 ' <-----<ERORR TRAP>----->
9000 IF ERL=8570 THEN PRINT ERHS"PROGRAM NOT FOUND":CLOSE:RESUME
8400
9099 IF ERR=2 AND (ERL=6820 OR ERL=2999) THEN RESUME NEXT 'CLS
9101 IF ERR=53 AND ERL=3917 THEN PRINT ERHS"NOT FOUND":RESUME 3910
'INSTUFF
9103 IF ERR=53 AND ERL=6950 THEN RESUME 6977 'SETOUT
9297 '
9300 IF ERR=54 THEN PRINT ERHS"CAN'T WRITE TO DISK":GOTO 9600
9310 IF ERR=57 THEN PRINT ERHS"DISK I/O ERROR":GOTO 9600
9320 IF ERR=62 THEN PRINT ERHS"PREMATURE EOF ON INPUT":GOTO 9600
9330 IF ERR=64 THEN PRINT ERHS"BAD FILE NAME":GOTO 9600
9340 IF ERR=61 THEN PRINT:PRINT ERHS"DISK FULL":GOTO 9600
9350 IF ERR=67 THEN PRINT ERHS"DISK DIRECTORY FULL":GOTO 9600
9360 IF ERR=70 THEN PRINT ERHS"DISK WRITE-PROTECTED":GOTO 9600
9500 PRINT:PRINT ERHS"SYSTEM ERROR"ERR
9600 PRINT ERHS"PROGRAM TERMINATED IN LINE"ERL
9900 CLOSE
9990 RESUME 8400

```

Anexo C Tablas de Resultados

Resultados con D₂

lis_testor = 1 2 3 6 9 11 12 17

Variables seleccionadas por el testor:8

RCE_grupo=2generaciones=10

	%pX	%pX2	%pXbin	%pPCA
	47.50	71.50	76.50	73.50
	68.00	72.00	83.50	80.00
	44.50	69.00	75.00	81.50
	57.50	80.00	83.50	71.00
	65.50	73.50	80.50	79.50
	46.50	77.50	83.50	74.50
	49.50	71.00	75.00	72.00
	74.00	71.00	81.50	77.00
	68.00	74.00	76.00	81.50
	53.00	72.50	82.50	75.50
Min	44.50	69.00	75.00	71.00
Pro	57.40	73.20	79.75	76.60
Med	55.25	72.25	81.00	76.25
Max	74.00	80.00	83.50	81.50

Tabla Anexo C.1 Validación cruzada con 2 grupos para D2.

RCE_grupo=3generaciones=10

	%pX	%pX2	%pXbin	%pPCA
	66.33	82.33	87.67	82.33
	72.33	81.33	90.67	88.67
	70.33	83.33	81.33	79.33
	67.67	80.33	92.67	88.67
	77.33	83.33	85.33	82.33
	71.33	83.33	87.67	89.67
	70.33	79.33	87.67	88.67
	71.67	85.00	86.00	86.00
	67.00	78.00	91.67	82.33
	71.33	80.67	86.00	86.00
Min	66.33	78.00	81.33	79.33
Pro	70.57	81.70	87.67	85.40
Med	70.83	81.83	87.67	86.00
Max	77.33	85.00	92.67	89.67

Tabla Anexo C.2 Validación cruzada con 3 grupos para D2.

RCE_grupo=4generaciones=10

	%pX	%pX2	%pXbin	%pPCA
	83.50	84.50	94.75	87.50
	72.50	87.00	88.00	87.00
	76.75	86.00	91.00	89.00
	84.50	84.50	90.75	87.50
	84.50	84.50	87.50	87.50
	78.50	84.50	87.50	87.50
	69.25	82.25	88.50	87.50
	76.00	87.50	91.75	90.75
	74.25	86.50	91.75	86.50
	82.00	84.00	93.00	91.00
Min	69.25	82.25	87.50	86.50
Pro	78.17	85.13	90.45	88.17
Med	77.63	84.50	90.88	87.50
Max	84.50	87.50	94.75	91.00

Tabla Anexo C.3 Validación cruzada con 4 grupos para D2.

RCE_grupo=5generaciones=10

	%pX	%pX2	%pXbin	%pPCA
	84.20	88.40	95.80	89.40
	86.60	89.40	93.60	88.40
	84.40	94.00	93.00	91.00
	84.60	92.00	93.00	94.00
	81.80	91.00	93.00	93.00
	81.00	89.00	91.00	92.00
	87.40	90.60	91.60	86.40
	78.40	88.40	91.60	92.60
	86.00	89.00	94.00	91.00
	86.60	93.60	93.60	91.60
Min	78.40	88.40	91.00	86.40
Pro	84.10	90.54	93.02	90.94
Med	84.50	90.00	93.00	91.30
Max	87.40	94.00	95.80	94.00

Tabla Anexo C.4 Validación cruzada con 5 grupos para D2.

Resultados con mutual

lis_testor = 2 3 4 5 13 14 24

Variables seleccionadas por el testor:7

RCE_grupo=2generaciones=10

	%pX	%pX2	%pXbin	%pPCA
	83.50	87.50	82.50	82.50
	84.50	82.50	79.00	86.50
	71.50	78.50	72.50	79.50
	80.50	83.50	76.50	80.50
	83.50	81.50	84.50	77.00
	83.50	82.50	81.50	77.00
	82.50	83.50	83.50	79.00
	78.00	80.00	84.50	83.50
	82.50	82.50	81.50	75.00
	82.50	77.50	79.50	80.50
Min	71.50	77.50	72.50	75.00
Pro	81.25	81.95	80.55	80.10
Med	82.50	82.50	81.50	80.00
Max	84.50	87.50	84.50	86.50

Tabla Anexo C.5 Validación cruzada con 2 grupos para Mutual.

RCE_grupo=3generaciones=10

	%pX	%pX2	%pXbin	%pPCA
	86.33	88.67	83.33	87.67
	88.67	84.33	89.67	84.33
	85.33	84.33	85.33	86.33
	88.00	87.00	91.00	89.00
	89.00	91.00	87.00	86.00
	86.33	88.67	86.33	88.67
	89.67	87.67	87.67	88.67
	82.33	81.33	87.67	90.67
	87.67	90.67	88.67	85.33
	88.67	93.67	84.33	86.33
Min	82.33	81.33	83.33	84.33
Pro	87.20	87.73	87.10	87.30
Med	87.83	88.17	87.33	87.00
Max	89.67	93.67	91.00	90.67

Tabla Anexo C.6 Validación cruzada con 3 grupos para Mutual.

RCE_grupo=4generaciones=10

	%pX	%pX2	%pXbin	%pPCA
	89.50	94.75	92.75	89.50
	87.50	90.75	89.50	91.75
	91.75	90.75	88.50	90.75
	90.75	89.50	85.50	87.50
	91.75	91.75	91.75	90.75
	91.75	94.75	91.75	89.50
	88.00	92.00	89.00	93.00
	91.75	92.75	88.50	92.75
	91.00	90.00	92.00	89.00
	91.75	91.75	89.50	89.50
Min	87.50	89.50	85.50	87.50
Pro	90.55	91.88	89.88	90.40
Med	91.38	91.75	89.50	90.13
Max	91.75	94.75	92.75	93.00

Tabla Anexo C.7 Validación cruzada con 4 grupos para Mutual.

RCE_grupo=5generaciones=10

	%pX	%pX2	%pXbin	%pPCA
	95.80	93.60	90.60	90.60
	92.00	91.00	90.00	90.00
	92.60	91.60	91.60	90.60
	95.00	95.00	93.00	90.00
	92.00	94.00	92.00	96.00
	92.00	93.00	92.00	89.00
	89.40	90.60	88.40	90.60
	91.60	92.60	88.40	95.80
	93.60	91.60	92.60	92.60
	87.40	89.40	91.60	90.60
Min	87.40	89.40	88.40	89.00
Pro	92.14	92.24	91.02	91.58
Med	92.00	92.10	91.60	90.60
Max	95.80	95.00	93.00	96.00

Tabla Anexo C.8 Validación cruzada con 5 grupos para Mutual.

Anexo D Código en Matlab




Figura Anexo-D.1 Esquema General de los programas

Los programas están al final de la tesis en un CD, junto con todo el material en digital.

Bibliografía

1. Begleiter, H. EEG-Setdata of the University of California, Irvine. *EEG Database* (1999). at <<http://kdd.ics.uci.edu/databases/eeg/eeg.full.html>>
2. Jiang, L. *et al.* Increased brain uptake and oxidation of acetate in heavy drinkers. *J. Clin. Invest.* **123**, 1605–1614 (2013).
3. Aoki, R., Wake, H., Sasaki, H. & Agata, K. Recording and spectrum analysis of the planarian electroencephalogram. *Neuroscience* **159**, 908–914 (2009).
4. Übeyli, E. D. Adaptive neuro-fuzzy inference system for classification of ECG signals using Lyapunov exponents. *Comput. Methods Programs Biomed.* **93**, 313–321 (2009).
5. Übeyli, E. D. Automatic detection of electroencephalographic changes using adaptive neuro-fuzzy inference system employing Lyapunov exponents. *Expert Syst. Appl.* **36**, 9031–9038 (2009).
6. Han, M. & Wang, Y. Analysis and modeling of multivariate chaotic time series based on neural network. *Expert Syst. Appl.* **36**, 1280–1290 (2009).
7. Abarbanel, H. D. I. *Analysis of observed chaotic data*. (Springer, 1996).
8. Wang, K., Fan, A. & Torres, A. Global properties of an improved hepatitis B virus model. *Nonlinear Anal. Real World Appl.* **11**, 3131–3138 (2010).
9. Ioannidis, J. P. A. Limits to forecasting in personalized medicine: An overview. *Spec. Sect. Decis. Mak. Plan. Low Levels Predict.* **25**, 773–783 (2009).
10. Tejera, E., Nieto-Villar, J. M. & Rebelo, I. Unexpected heart rate variability complexity in the aging process of arrhythmic subjects. *Commun. Nonlinear Sci. Numer. Simul.* **15**, 1858–1863 (2010).
11. Fan, D. & Hong, L. Hopf bifurcation analysis in a synaptically coupled FHN neuron model with delays. *Commun. Nonlinear Sci. Numer. Simul.* **15**, 1873–1886 (2010).
12. Cai, L., Guo, S., Li, X. & Ghosh, M. Global dynamics of a dengue epidemic mathematical model. *Chaos Solitons Fractals* **42**, 2297–2304 (2009).
13. Pascolo, P., Carniel, R. & Grimaz, S. Dynamical models of the human eye and strabismus. *Chaos Solitons Fractals* **41**, 2463–2470 (2009).
14. Gois, S. R. F. S. M. & Savi, M. A. An analysis of heart rhythm dynamics using a three-coupled oscillator model. *Chaos Solitons Fractals* **41**, 2553–2565 (2009).
15. Gordoia, P. R. A note on solutions of an equation modelling arterial deformation. *Chaos Solitons Fractals* **33**, 1505–1511 (2007).
16. Hegger, R., Kantz, H. & Schreiber, T. Practical implementation of nonlinear time series methods: The TISEAN package. *Chaos Interdiscip. J. Nonlinear Sci.* **9**, 413 (1999).

17. Hughes, J. R. A review of the usefulness of the standard EEG in psychiatry. *Clin. EEG Electroencephalogr.* **27**, 35–39 (1996).
18. Hughes, J. R. & John, E. R. Conventional and quantitative electroencephalography in psychiatry. *J. Neuropsychiatry Clin. Neurosci.* **11**, 190–208 (1999).
19. Instituto Nacional de Psiquiatría Ramón de la Fuente Muñiz / Secretaría de Salud. *Encuesta Nacional de Adicciones 2011: Reporte de Drogas.* (Instituto Nacional de Psiquiatría Ramón de la Fuente Muñiz / Secretaría de Salud). at <www.cenadic.salud.gob.mx, www.insp.mx>
20. Acharya, U. R., Vinitha Sree, S., Swapna, G., Martis, R. J. & Suri, J. S. Automated EEG analysis of epilepsy: A review. *Knowl.-Based Syst.* **45**, 147–165 (2013).
21. Shalbaf, R., Behnam, H., Sleight, J. W., Steyn-Ross, A. & Voss, L. J. Monitoring the depth of anesthesia using entropy features and an artificial neural network. *J. Neurosci. Methods* **218**, 17–24 (2013).
22. Oâ€™Regan, S., Faul, S. & Marnane, W. Automatic detection of EEG artefacts arising from head movements using EEG and gyroscope signals. *Med. Eng. Phys.* doi:10.1016/j.medengphy.2012.08.017
23. Song, Y. & Zhang, J. Automatic recognition of epileptic EEG patterns via Extreme Learning Machine and multiresolution feature extraction. *Expert Syst. Appl.* doi:10.1016/j.eswa.2013.04.025
24. Parvinnia, E., Sabeti, M., Zolghadri Jahromi, M. & Boostani, R. Classification of EEG Signals using adaptive weighted distance nearest neighbor algorithm. *J. King Saud Univ. - Comput. Inf. Sci.* doi:10.1016/j.jksuci.2013.01.001
25. Shirvany, Y., Edelvik, F., Jakobsson, S., Hedström, A. & Persson, M. Application of particle swarm optimization in epileptic spike EEG source localization. *Appl. Soft Comput.* **13**, 2515–2525 (2013).
26. Kannathal, N., Acharya, U. R., Lim, C. M. & Sadasivan, P. K. Characterization of EEG—A comparative study. *Comput. Methods Programs Biomed.* **80**, 17–23 (2005).
27. Weiss, B., Clemens, Z., Bădăuz, Răz. & Halász, Pă. Comparison of fractal and power spectral EEG features: Effects of topography and sleep stages. *Brain Res. Bull.* **84**, 359–375 (2011).
28. Ouyang, G., Li, J., Liu, X. & Li, X. Dynamic characteristics of absence EEG recordings with multiscale permutation entropy analysis. *Epilepsy Res.* **104**, 246–252 (2013).
29. Brodu, N., Lotte, F. & Lécuyer, A. Exploring two novel features for EEG-based brain-computer interfaces: Multifractal cumulants and predictive complexity. *Neurocomputing* **79**, 87–94 (2012).
30. Echeverría, J. C. et al. Fractal and nonlinear changes in the long-term baseline fluctuations of fetal heart rate. *Med. Eng. Phys.* **34**, 466–471 (2012).
31. Abhishekh, H. A. et al. Ictal EEG fractal dimension in ECT predicts outcome at 2 weeks in schizophrenia. *Psychiatry Res.* (2012). at <<http://linkinghub.elsevier.com/retrieve/pii/S0165178112007858?showall=true>>
32. Caballero-Gaudes, C. et al. Mapping interictal epileptic discharges using mutual information between concurrent EEG and fMRI. *Neuroimage* **68**, 248–262 (2013).
33. Mandelbrot, B. B. *The fractal geometry of nature.* (W.H. Freeman, 1982).

34. Brignol, A., Al-ani Tarik & Drouot, X. Phase space and power spectral approaches for EEG-based automatic sleep-wake classification in humans: A comparative study using short and standard epoch lengths. *Comput. Methods Programs Biomed.* **109**, 227–238 (2013).
35. Sriraam, N. Correlation dimension based lossless compression of EEG signals. *Biomed. Signal Process. Control* **7**, 379–388 (2012).
36. Hartmann, A. et al. Real-time fractal signal processing in the time domain. *Phys. Stat. Mech. Its Appl.* **392**, 89–102 (2013).
37. Livi, R. On brain fluctuations and the challenges ahead. *Chaos Solitons Fractals* doi:10.1016/j.chaos.2013.03.007
38. De Munck, J. C., van Houdt, P. J., Gonçalves, S. I., van Wegen, E. & Ossenblok, P. P. W. Novel artefact removal algorithms for co-registered EEG/fMRI based on selective averaging and subtraction. *Neuroimage* **64**, 407–415 (2013).
39. Tang, Q., Wang, J. & Wang, H. L1-norm based discriminative spatial pattern for single-trial EEG classification. *Biomed. Signal Process. Control* doi:10.1016/j.bspc.2012.12.004
40. Contreras-Troya, T., Morales-Matamoros, O., Trueba-Ríos, B., Tejeida-Padilla, R. & Balankin, A. - Análisis fractal de la epilepsia. - *Científica* - **13**, - 85–94 (2009).
41. Der Lange. *Generalized 3 Hz spike and wave discharges in a child with childhood absence epilepsy.* (2006). at <<http://commons.wikimedia.org/w/index.php?title=File:Spike-waves.png&action=edit§ion=2>>
42. Pagliarini, J. *Imagen de los lóbulos cerebrales diferenciados por colores.* (2012). at <<http://us.123rf.com/400wm/400/400/medusa81/medusa811105/medusa81110500003/9640692-vista-lateral-del-cerebro-humano.jpg>>
43. Santiago Ramón y Cajal. *Drawing of Purkinje cells (A) and granule cells (B) from pigeon cerebellum by Santiago Ramón y Cajal.* (1899). at <<http://upload.wikimedia.org/wikipedia/commons/1/15/PurkinjeCell.jpg>>
44. LadyofHats. *Complete neuron cell diagram.* *Neurons.* (2007). at <http://commons.wikimedia.org/wiki/File:Complete_neuron_cell_diagram_en.svg>
45. *Texto y atlas de anatomia 2 / Text and Atlas of Anatomy Cabeza, Cuello Y Neuroanatomia / Head, Neck, and Neuroanatomy.* (Editorial Medica Panamericana Sa de, 2011).
46. Sheng Bao. *32-, 64- and 128-channel EEG sampling system.* (2011). at <<http://fsbao.net>>
47. Snodgrass, J. G. & Vanderwart, M. A standardized set of 260 pictures: norms for name agreement, image agreement, familiarity, and visual complexity. *J. Exp. Psychol. [Hum. Learn.]* **6**, 174–215 (1980).
48. Zhang, X. L., Begleiter, H., Porjesz, B., Wang, W. & Litke, A. Event related potentials during object recognition tasks. *Brain Res. Bull.* **38**, 531–538 (1995).
49. Shannon, C. E. A mathematical theory of communication. *ACM SIGMOBILE Mob. Comput. Commun. Rev.* **5**, 3 (2001).
50. Zhu, H. & Dong, J. An R-peak detection method based on peaks of Shannon energy envelope. *Biomed. Signal Process. Control* **8**, 466–474 (2013).

51. Trinidad Segovia, J. E., Fernández-Martínez, M. & Sánchez-Granero, M. A. A note on geometric method-based procedures to calculate the Hurst exponent. *Phys. Stat. Mech. Its Appl.* **391**, 2209–2214 (2012).
52. Lazo-Cortes, M., Ruiz-Shulcloper, J. & Alba-Cabrera, E. An overview of the evolution of the concept of testor. *Pattern Recognit.* **34**, 753–762 (2001).
53. Martínez-Trinidad, J. F. & Guzmán-Arenas, A. The logical combinatorial approach to pattern recognition, an overview through selected works. *Pattern Recognit.* **34**, 741–751 (2001).
54. Carrasco-Ochoa, J. A. & Ruiz-Shulcloper, J. Sensitivity analysis of fuzzy Goldman typical testors. *Fuzzy Sets Syst.* **141**, 241–257 (2004).
55. Rojas, A., Cumplido, R., Ariel Carrasco-Ochoa, J., Feregrino, C. & Francisco Martínez-Trinidad, J. Hardware–software platform for computing irreducible testors. *Expert Syst. Appl.* **39**, 2203–2210 (2012).
56. Hancock, E., Martínez-Trinidad, J. F. & Carrasco-Ochoa, J. A. Advances in pattern recognition methodology and applications. *Pattern Recognit. Lett.* **34**, 359–360 (2013).
57. Shulcloper, J. R., Aguila, L. & Bravo, A. Algoritmo BT y TB para el cálculo de todos los test típicos. *Rev. Ciencias Matemáticas* **4**, 11–18 (1985).
58. McCulloch, W. S. & Pitts, W. A logical calculus of the ideas immanent in nervous activity. *Bull. Math. Biophys.* **5**, 115–133 (1943).
59. McCulloch, W. S. A heterarchy of values determined by the topology of nervous nets. *Bull. Math. Biophys.* **7**, 89–93 (1945).
60. Schlatter, M. & Aizawa, K. Walter Pitts and ‘A Logical Calculus’. *Synthese* **162**, 235–250 (2007).
61. Yin, X., Guo, D. & Xie, M. Hand image segmentation using color and RCE neural network. *Robot. Auton. Syst.* **34**, 235–250 (2001).
62. Bu, W., Wang, K., Wu, X., Cui, X. & Zhao, Q. Hand Segmentation for Hand-based Biometrics in Complex Environments. *J. Softw.* **8**, (2013).
63. Tian, J. *et al.* Design of Si-based flat-top steep-edge RCE photodetector with two-coupled-cavity grating filter. *Opt. Laser Technol.* **45**, 620–624 (2013).
64. Sui, C., Kwok, N. M. & Ren, T. A Restricted Coulomb Energy (RCE) Neural Network System for Hand Image Segmentation. in 270–277 (IEEE, 2011). doi:10.1109/CRV.2011.43
65. Hsieh, P.-C. & Tung, P.-C. A novel hybrid approach based on sub-pattern technique and whitened PCA for face recognition. *Pattern Recognit.* **42**, 978–984 (2009).
66. Zhou, C., Wang, L., Zhang, Q. & Wei, X. Face recognition based on PCA image reconstruction and LDA. *Opt. - Int. J. Light Electron Opt.* **124**, 5599–5603 (2013).
67. Chen, S. & Zhu, Y. Subpattern-based principle component analysis. *Pattern Recognit.* **37**, 1081–1083 (2004).