



**ANÁLISIS DE SEÑALES EEG CON REGISTROS DE EPILEPSIA MEDIANTE RECONOCIMIENTO DE PATRONES Y TRANSFORMADA WAVELET**



**Lina Andrea Arcila Armero  
Liceth Yuliana Cajas Hoyos**

Director: MSc. Harold Armando Romo Romero

*Universidad del Cauca*  
Facultad de Ingeniería Electrónica y de Telecomunicaciones  
Departamento de Telecomunicaciones  
Grupo Nuevas Tecnologías en Telecomunicaciones GNTT  
Popayán, Agosto de 2016



ANÁLISIS DE SEÑALES EEG CON REGISTROS DE EPILEPSIA MEDIANTE RECONOCIMIENTO DE PATRONES Y TRANSFORMADA WAVELET.

---



## ANÁLISIS DE SEÑALES EEG CON REGISTROS DE EPILEPSIA MEDIANTE RECONOCIMIENTO DE PATRONES Y TRANSFORMADA WAVELET



Trabajo de Grado presentado como requisito parcial para obtener el título de Ingeniero en Electrónica y Telecomunicaciones

**Lina Andrea Arcila Armero  
Liceth Yuliana Cajas Hoyos**

Director: MSc. Harold Armando Romo Romero

*Universidad del Cauca*  
Facultad de Ingeniería Electrónica y de Telecomunicaciones  
Departamento de Telecomunicaciones  
Grupo Nuevas Tecnologías en Telecomunicaciones GNTT  
Popayán, Agosto de 2016



ANÁLISIS DE SEÑALES EEG CON REGISTROS DE EPILEPSIA MEDIANTE RECONOCIMIENTO DE PATRONES Y TRANSFORMADA WAVELET.

---



## AGRADECIMIENTOS

*A Dios y la Virgen María por bendecirnos diariamente, por darnos fuerza y fe para creer en lo que nos parecía imposible de terminar.*

*Al MSc. Harold Romo nuestro más sincero agradecimiento y reconocimiento por su supervisión, asesoramiento, orientación y observaciones dadas a lo largo de la realización de este proyecto. Por su apoyo, paciencia y comprensión, porque más que un asesor del trabajo se convirtió en un gran amigo.*

*A nuestras familias agradecemos por su incondicional amor y apoyo, con lo que se convirtieron en la fuente de motivación e inspiración para el desarrollo de este trabajo.*



ANÁLISIS DE SEÑALES EEG CON REGISTROS DE EPILEPSIA MEDIANTE RECONOCIMIENTO DE PATRONES Y TRANSFORMADA WAVELET.

---



## TABLA DE CONTENIDO

	<b>Pág.</b>
INTRODUCCIÓN.....	1
CAPITULO 1 GENERALIDADES DE SEÑALES EEG.....	5
1.1. INTRODUCCIÓN.....	5
1.2. MARCO CONCEPTUAL.....	5
1.2.1. Epilepsia .....	5
1.2.2. Estados epilépticos.....	6
1.2.3. Electroencefalografía.....	7
1.3. GENERACIÓN DE SEÑALES EEG .....	8
1.3.1. Sistema Nervioso .....	8
1.3.2. Potencial de acción .....	9
1.4. DESCRIPCIÓN ELÉCTRICA DE LAS SEÑALES EEG .....	10
1.5. CAPTURA DE LAS SEÑALES EEG .....	12
1.5.1. Consideraciones de ruido.....	16
CAPITULO 2 PROCESAMIENTO DIGITAL DE UNA SEÑAL EEG PARA SU CLASIFICACIÓN.....	19
2.1. EXTRACCIÓN DE CARACTERÍSTICAS .....	22
2.1.1. Análisis temporal .....	23
2.1.2. Análisis espectral con Wavelet .....	27
2.1.3. Extracción de características basadas en wavelets. ....	36
2.2. REDUCCIÓN DE DIMENSIONALIDAD .....	41
2.2.1. Selección de características.....	42
2.3. CLASIFICACIÓN DE PATRONES .....	44
2.3.1. Formas de clasificación.....	44
2.3.2. Fundamentos teóricos de los clasificadores.....	46
CAPITULO 3 DISEÑO E IMPLEMENTACIÓN DEL ALGORITMO DE EXTRACCIÓN DE CARACTERÍSTICAS.....	59
3.1. FASE DE ANÁLISIS .....	59
3.2. FASE DE DISEÑO.....	60
3.2.1. Wavelet Toolboxes .....	61
3.2.2. Selección de la base de datos de señales EEG.....	61



3.2.3. Selección de canales y características mediante CSI .....	63
3.2.4. Características Temporales .....	65
3.2.5. Características Espectrales DWT .....	68
3.2.6. Conformación de los vectores simples (DT y DWT) e híbridos (DT - DWT).....	74
3.3. FASE DE IMPLEMENTACIÓN .....	74
3.3.1. Extracción de Características en el dominio del tiempo .....	74
3.3.2. Extracción de Características en el dominio espectral .....	75
3.3.3. Índice de Separabilidad de Clases .....	75
CAPITULO 4 CLASIFICACIÓN DE PATRONES EEGs.....	77
4.1. ERROR DE CLASIFICACIÓN PARA LAS CARACTERÍSTICAS DT, DWT Y DT-DWT.....	78
4.2. IMPLEMENTACIÓN DE ALGORITMOS Y FUNCIONES .....	84
4.2.1. Cuerpo Principal del Sistema .....	84
4.2.2. Algoritmo de Clasificación .....	84
CAPITULO 5 CONCLUSIONES Y TRABAJOS FUTUROS.....	89
5.1. CONCLUSIONES.....	89
5.2. TRABAJOS FUTUROS .....	91
REFERENCIAS.....	93
Anexo A. Información de la base de datos.....	103
APÉNDICE I. CÁLCULO DE LOS PROMEDIOS CSI PARA LOS PARÁMETROS TEMPORALES.....	107
APÉNDICE II. CÁLCULO DE LOS PROMEDIOS CSI PARA LOS PARÁMETROS ESPECTRALES.....	119



## Lista de Figuras

	Pág.
Figura 1.1. Estructura de la neurona .....	9
Figura 1.2. Ondas cerebrales típicas.....	11
Figura 1.3. Vista de perfil .....	14
Figura 1.4. Vista superior.....	14
Figura 1.5. Ubicación y nomenclatura de los electrodos intermedios, estandarizada por la Sociedad Americana de Electroencefalografía .....	15
Figura 2.1. Detección de las señales EEG.....	20
Figura 2.2. Anidamiento de subespacios wavelets $\Omega_j, 1$ y escalas $\Omega_j, 0$ para $J = 3$ . 32	32
Figura 2.3. Estructura DWT a un nivel ( $J = 1$ ).....	33
Figura 2.4. Proceso de transformación discreta de wavelets para $J = 3$ . .....	34
Figura 2.5. Descomposición y reconstrucción DWT a nivel 5 de una señal EEG.....	36
Figura 2.6. Etapas para extracción de características y clasificación de una señal..	41
Figura 2.7. Problema separable linealmente.....	45
Figura 2.8. Problema no separable linealmente. ....	45
Figura 2.9. Funcionamiento de una SVM.....	47
Figura 2.10. SVM linealmente separable. Selección del hiperplano de separación óptimo.....	49
Figura 2.11. SVM linealmente separable.Margen blando.....	50
Figura 2.12. SVM no linealmente separable. Transformación de los datos de entrada a un espacio de mayor dimensión inducida por una función kernel.....	51
Figura 2.13. Arquitectura de una red PNN. ....	54
Figura 2.14. Estructura de un MLP con una capa de entrada y tres capas activas..	55
Figura 2.15. Funciones de activación comunes.....	56
Figura 3.1. Estados que se presentan en una señal EEG.....	59
Figura 3.2. EEG correspondiente al paciente 5 de entreno.....	62
Figura 3.3. Traslape o separabilidad de clases según el índice CSI.....	64
Figura 3.4. Promedios CSI para los parámetros temporales evaluados en dos canales. ....	67
Figura 3.5. Promedios CSI para los parámetros espectrales sobre la matriz de coeficientes DWT .....	73
Figura 4.1. Error promedio de clasificación de 3 estados para los vectores descriptores DT, DWT, DT-DWT.....	80
Figura 4.2. Matriz de confusión .....	81
Figura 4.3. Error promedio de clasificación de 2 estados para los vectores descriptores DT, DWT, DT-DWT.....	83



## Lista de Tablas

	<b>Pág.</b>
Tabla 1.1. Descripción de las ondas cerebrales típicas .....	12
Tabla 1.2. Nomenclatura empleada en el sistema internación 10-20.....	16
Tabla 3.1. Mejores canales según el CSI para los parámetros temporales .....	66
Tabla 3.2. División de frecuencias a una tasa de muestreo de la señal de 256 Hz a un nivel de descomposición 5 .....	69
Tabla 3.3. División de frecuencias a una tasa de muestreo de la señal de 256 Hz a un nivel de descomposición 4 .....	70
Tabla 3.4. Mejores canales según el CSI para los parámetros espectrales.....	72
Tabla 4.1. Error de clasificación SVM de 3 estados (normal, ictal y postictal) para los vectores simples e híbridos.....	79
Tabla 4.2. Error de clasificación PNN de 3 estados (normal, ictal y postictal) para los vectores simples e híbridos.....	79
Tabla 4.3. Error de clasificación MLP de 3 estados (normal, ictal y postictal) para los vectores simples e híbridos.....	79
Tabla 4.4. Error de clasificación SVM de 2 estados (normal e ictal) para los vectores simples e híbridos.....	82
Tabla 4.5. Error de clasificación PNN de 2 estados (normal e ictal) para los vectores simples e híbridos.....	82
Tabla 4.6. Error de clasificación MLP de 2 estados (normal e ictal) para los vectores simples e híbridos.....	82
Tabla A.1. Configuración de canales según el sistema internacional 10-20, para los pacientes 1, 3 y 5 .....	103
Tabla A.2. Configuración de canales según el sistema internacional 10-20, para el pacientes 2 y 4.....	104
Tabla A.3. Edad y sexo de los registros de la base de datos .....	105
Tabla I.1. Promedios CSI para el parámetro media evaluado en cada canal para los 5 pacientes.....	107
Tabla I.2. Promedios CSI para el parámetro varianza evaluado en cada canal para los 5 pacientes .....	108
Tabla I.3. Promedios CSI para el parámetro desviación estándar evaluado en cada canal para los 5 pacientes.....	109
Tabla I.4. Promedios CSI para el parámetro Asimetría evaluado en cada canal para los 5 pacientes.....	110
Tabla I.5. Promedios CSI para el parámetro curtosis evaluado en cada canal para los 5 pacientes. ....	111
Tabla I.6. Promedios CSI para el parámetro coeficiente de variación evaluado en cada canal para los 5 pacientes.....	112



Tabla I.7. Promedios CSI para el parámetro VMA evaluado en cada canal para los 5 pacientes.....	113
Tabla I.8. Promedios CSI para el parámetro CC evaluado en cada canal para los 5 pacientes.....	114
Tabla I.9. Promedios CSI para el parámetro CSP evaluado en cada canal para los 5 pacientes.....	115
Tabla I.10. Promedios CSI para el parámetro LO evaluado en cada canal para los 5 pacientes.....	116
Tabla II.1. Promedios CSI para el parámetro SVD evaluado en cada canal para los 5 pacientes.....	119
Tabla II.2. Promedios CSI para el parámetro ENER evaluado en cada canal para los 5 pacientes.....	120
Tabla II.3. Promedios CSI para el parámetro AVG evaluado en cada canal para los 5 pacientes.....	121
Tabla II.4. Promedios CSI para el parámetro MAX evaluado en cada canal para los 5 pacientes.....	122
Tabla II.5. Promedios CSI para el parámetro VAR evaluado en cada canal para los 5 pacientes.....	123
Tabla II.6. Promedios CSI para el parámetro ApEn evaluado en cada canal para los 5 pacientes.....	124
Tabla II.7. Promedios CSI para el parámetro Entropía muestral evaluado en cada canal para los 5 pacientes.....	125
Tabla II.8. Promedios CSI para el parámetro Entropía espectral evaluado en cada canal para los 5 pacientes.....	126

### Lista de Acrónimos

**ANNs** : *Artificial Neural Networks*, Redes Neuronales Artificiales.

**CSI** : *Class Separability Index*, Índice de Separabilidad de Clases.

**CWT** : *Continuous Wavelet Transform*, Transformada Wavelet Continua.



- DT** : *Domain Time*, Dominio Temporal.
- DWT** : *Discrete Wavelet Transform*, Transformada Wavelet Discreta.
- ECG** : *Electrocardiogram*, Electrocardiograma.
- ECoG** : *Electrocorticogram*, Electrocardiograma.
- EEG** : *Electroencephalogram*, Electroencefalograma.
- EMG** : *Electromyogram*, Electromiograma.
- EOG** : *Electrooculogram*, Electrooculograma.
- FFT** : *Fast Fourier Transform*, Transformada Rápida de Fourier.
- FIS** : *Fuzzy Interference System*, Sistema de Interferencia Fuzzy.
- FT** : *Fourier Transform*, Transformada de Fourier.
- ILAE** : *International League Against Epilepsy*, Liga Internacional Contra la Epilepsia.



- MIT** : *Massachusetts Institute of Technology*, Instituto Tecnológico de Massachusetts.
- MLP** : *Multi Layer Perceptron*, Perceptrón Multicapas.
- MRA** : *Multiresolution Analysis*, Análisis Multiresolución.
- MRI** : *Magnetic Resonance Image*, Imagen de Resonancia Magnética.
- PCA** : *Principal Components Analysis*, Análisis de Componentes Principales.
- PDF** : *Probability Density Function*, Función de Densidad de Probabilidad
- PDS** : *Digital Signal Processing*, Procesamiento Digital de Señales.
- PNN** : *Probabilistic Neuronal Network*, Red Neuronal Probabilística.
- PSD** : *Power Spectral Density*, Densidad Espectral de Potencia.
- RBF** : *Radial Basis Function*, Función de Base Radial.
- RBFN** : *Radial Function Network*, Red de Función Radial.



- SEEG** : *Stereo Electroencephalogram*, Estéreo Electroencefalograma.
- STFT** : *Short Time Fourier Transform*, Transformada de Fourier de Tiempo Corto.
- SVD** : *Singular Value Decomposition*, Descomposición de Valores Singulares
- SVM** : *Multiclass Support Vector Machine*, Máquina de Soporte Vectorial Multiclase.
- WT** : *Wavelet Transform*, Transformada Wavelet.
- WPT** : *Wavelet Packet Transform*, Transformada de Paquetes Wavelet.



ANÁLISIS DE SEÑALES EEG CON REGISTROS DE EPILEPSIA MEDIANTE RECONOCIMIENTO DE  
PATRONES Y TRANSFORMADA WAVELET.

---





## INTRODUCCIÓN

Los avances de la humanidad han venido acompañados de grandes interrogantes, algunos de estos se han logrado responder gracias a los desarrollos en las ciencias, pero otros hasta ahora no son claros, ni siquiera con las investigaciones complejas y trabajos que se han realizado. Uno de estos interrogantes es el funcionamiento del cerebro humano, el cual ha sido estudiado por décadas en sus funciones normales, pero cuando éste presenta algún problema, es indispensable reformular teorías que ya están dadas e inclusive algunas veces iniciar desde cero en las investigaciones. Este es el caso de una de las anomalías del cerebro que se ha presentado desde la historia de la humanidad, la epilepsia<sup>1</sup>.

Según la Organización Mundial de la Salud [1], cientos de millones de personas en el mundo sufren de algún tipo de trastorno neurológico, entre ellos: epilepsia, Alzheimer, accidentes cerebrovasculares y dolor de cabeza. Con respecto a la epilepsia, se tiene que ésta es la segunda enfermedad neurológica que más sufren en el mundo, cerca de 50 millones de personas la padecen [2]. La epilepsia es una patología que ha acompañado siempre a la humanidad; sin embargo, solo fue diagnosticada en el año 1849 por el médico Robert Bentley, la formulación de tratamientos farmacológicos se da en el año

---

<sup>1</sup> Epilepsia: es una enfermedad cerebral crónica que afecta a personas de todo el mundo y se caracteriza por convulsiones recurrentes. Estas convulsiones son episodios breves de movimientos involuntarios que pueden afectar a una parte del cuerpo (convulsiones parciales) o a su totalidad (convulsiones generalizadas) y a veces se acompañan de pérdida de la consciencia y del control de los esfínteres.



1856, y 40 años después se crea la Liga Internacional Contra la Epilepsia (ILAE, *International League Against Epilepsy*) en Budapest [3].

Entre las herramientas que se tienen para el diagnóstico de trastornos neurológicos está el Electroencefalograma (EEG, *Electroencephalogram*), a través de éste, se registra la actividad eléctrica del cerebro. Las señales que se logran observar gracias al EEG pueden ser obtenidas de manera no invasiva, es decir, mediante electrodos ubicados sobre la superficie del cuero cabelludo del paciente. Cabe resaltar que el análisis de estas señales se ha convertido en un método eficiente y básico en estudios de valoración clínica; sin embargo, aún son elemento de investigación alrededor del mundo y con enormes desafíos debido a la complejidad del análisis de patrones neuronales recopilados en los EEG [4].

La clasificación de las ondas epileptiformes<sup>2</sup> en el EEG tiene gran importancia clínica, ya que estas pueden ser indicio de que la persona está padeciendo epilepsia. Para realizar una óptima clasificación, primero se debe realizar un proceso de extracción de características en las señales EEG, lo cual ayudará a mejorar el desempeño en la clasificación de las mismas. La extracción de características en señales EEG se ha investigado mediante la aplicación de diversas técnicas espectrales, por ejemplo, transformadas basadas en el análisis de Fourier, tales como: la Transformada Rápida de Fourier (FFT, *Fast Fourier Transform*) y la Transformada de Fourier de Tiempo Corto (STFT, *Short Time Fourier Transform*); estas técnicas han sido usadas para definir el espectro de una señal EEG que, por su naturaleza no estacionaria, no resultan ser apropiadas; en su lugar la transformada wavelet ha sido utilizada en las más modernas investigaciones de análisis de señales biomédicas y clasificación de patrones presentes, por ejemplo, en la epilepsia [5] [6].

A partir de lo anterior, este trabajo de grado aplica el Procesamiento Digital de Señales (PDS, *Digital Signal Processing*) en el análisis de las señales

---

<sup>2</sup> Ondas epileptiformes: estas anomalías consisten en ondas lentas focales o generalizadas que se destacan de la actividad de base por un súbito cambio en amplitud y frecuencia.



bioeléctricas EEG con registros de epilepsia, utilizando como herramienta de análisis la Transformada Wavelet (WT, *Wavelet Transform*).

Este documento se divide en cinco capítulos, estructurados de la siguiente manera:

Capítulo I. Se presentan los conceptos fundamentales relacionados con señales EEG, resaltando su generación, descripción eléctrica y detección.

Capítulo II. Se hace una explicación general de las técnicas de análisis y extracción de características, tanto temporales como espectrales basadas en wavelets, esto por medio de la Transformada Wavelet Discreta para fines de clasificación de patrones EEGs. Por otra parte, se realiza una investigación de ciertas técnicas de reducción de dimensionalidad y de clasificación de patrones, considerando las más adecuadas para fines del trabajo de grado.

Capítulo III. Describe la implementación y simulación del algoritmo de extracción de características de señales EEG, con registros de epilepsia.

Capítulo IV. Se mide el desempeño del algoritmo implementado en el capítulo previo, mediante el error en la clasificación de los patrones EEGs.

Capítulo V. Se exponen las conclusiones y recomendaciones obtenidas del desarrollo de todo el proyecto, y se presentan una serie de ideas para futuros trabajos e investigaciones en este campo.





# CAPÍTULO 1

## GENERALIDADES DE SEÑALES EEG

### 1.1. INTRODUCCIÓN

La clasificación de señales electroencefalográficas (EEGs) es ampliamente utilizada en estudios de valoración clínica, principalmente en el diagnóstico y tratamiento de trastornos neurológicos como la epilepsia. El análisis EEG que se realiza en este trabajo busca encontrar una representación correspondiente y apropiada de las señales a través de un grupo de características que las describa, es decir, que posea la información más importante para su posterior discriminación y clasificación buscando el mínimo error aceptable.

### 1.2. MARCO CONCEPTUAL

#### 1.2.1. Epilepsia

La epilepsia es un trastorno neurológico crónico, se caracteriza por episodios de descargas eléctricas recurrentes, bruscas e incontrolables conocidas como convulsiones o crisis epileptiformes. Estas convulsiones, son movimientos



involuntarios generados por una descarga eléctrica anormal de una población de neuronas<sup>3</sup>, las cuales se pueden generar en diferentes lugares del cerebro [2].

En el diagnóstico de la epilepsia las convulsiones no son suficientes para determinar si una persona padece esta patología, ya que estas se pueden producir por otras razones como la fiebre. Por ello, para un diagnóstico final se debe hacer una historia clínica detallada, un EEG y una Imagen de Resonancia Magnética<sup>4</sup> (MRI, *Magnetic Resonance Image*) en casos muy particulares [3].

Es importante no confundir crisis convulsiva con epilepsia, ya que la primera es un trastorno funcional de las células neuronales de un área específica del cerebro, y la segunda es la reunión de las crisis; éstas últimas se pueden clasificar en parciales (se presenta en un área específica del cerebro) o generalizadas (en todo el cerebro) [2].

### 1.2.2. Estados epilépticos.

En pacientes epilépticos, se pueden identificar cuatro estados según la relación que guarden con la crisis, estos son: preictal, ictal, postictal e interictal [7].

- **Preictal:** es el estado inmediatamente anterior a la crisis, se caracteriza por inactividad o lentificación mental, irritabilidad y caída del estado de ánimo [7].
- **Ictal:** es el estado que se presenta durante una convulsión, algunas de sus características pueden ser: movimientos de búsqueda de la cabeza, los ojos y otras partes del cuerpo; crepitación de los labios; movimientos

---

<sup>3</sup> Neuronas: son las células funcionales del tejido nervioso. Ellas se interconectan formando redes de comunicación que transmiten señales por zonas definidas del sistema nervioso.

<sup>4</sup> Imagen de Resonancia Magnética: es un procedimiento para el que se usan ondas de radio y un imán muy potente conectado a una computadora, para crear ilustraciones detalladas de áreas internas del cuerpo. Estas imágenes pueden mostrar la diferencia entre el tejido normal y el tejido enfermo.



masticatorios o deglutorios; salivación abundante; desorientación parcial y aparición de automatismos<sup>5</sup> complejos [7].

- **Postictal:** es el estado alterado de conciencia (sin deterioro motor o lingüístico), en el que entra una persona después de tener una crisis convulsiva. El paciente despierta confundido, desorientado, refunfuñando cosas incoherentes, revolviendo sus ropas. Aparecen crisis de excitación que duran minutos, agitación extrema, ideación paranoide, alucinaciones e ilusiones que conllevan a la agresividad, comportándose de forma peligrosa para él y para los demás [7].
- **Interictal:** es el tiempo que transcurre entre una crisis y la siguiente [7].

Cabe resaltar que la duración del estado postictal, es fundamental por las implicaciones en el pronóstico y la funcionalidad del paciente; algunas características de este estado, pueden contribuir a localizar la región del cerebro donde se generó la crisis. Por otra parte, se tiene que las pruebas cognitivas en el estado postictal puede ser de mayor valor que las pruebas entre crisis, sobre todo durante la evaluación pre-quirúrgica [8-11].

De lo anterior se concluye que el estado postictal puede contribuir en el pronóstico médico de la epilepsia. Es por esto que en el presente trabajo de grado se buscó diferenciar el estado normal y los epilépticos (ictal y postictal) de una persona.

### 1.2.3. Electroencefalografía

Hans Berger es considerado el padre de la electroencefalografía, ya que fue el primero en estudiarla y aplicarla, esta es una técnica que permite grabar e interpretar la actividad eléctrica del cerebro, la cual se realiza a través de una

---

<sup>5</sup> Automatismo: falta de intervención de la voluntad, la reflexión o la conciencia plena en la realización de movimientos o actos mentales.



prueba conocida como electroencefalograma (EEG) y mediante el uso de un equipo llamado electroencefalógrafo [12].

## **1.3. GENERACIÓN DE SEÑALES EEG**

### **1.3.1. Sistema Nervioso**

El Sistema Nervioso se encarga de guardar información sobre el mundo exterior y sobre el estado del organismo, posteriormente estudia esta información para decidir cuál es la respuesta que debe ejecutar en cada momento. A partir de la relación estímulo-respuesta, se logra una comunicación con el entorno, esto se da debido a las sensaciones externas que reciben los seres humanos. Las respuestas que se generan a los estímulos se ven reflejadas en la transmisión de señales eléctricas a través de las células nerviosas a diferentes regiones del cerebro donde son interpretadas. Por tanto, se puede concluir que la función del sistema nervioso es en esencia la de transmitir señales [13].

El Sistema Nervioso Central (SNC) tiene dos tipos de células, las gliales y las neuronas. Las neuronas son unidades altamente interconectadas cuya función es recibir y transmitir impulsos eléctricos, integrando de esta forma la información que reciben y produciendo una respuesta de acuerdo a la misma. Las células gliales están encargadas de apoyar, proteger, alimentar y regular las neuronas. Las neuronas tienen tres componentes principales, las dendritas, el cuerpo de la célula o soma y el axón. Las dendritas son ramificaciones terminales y son las encargadas de la recepción de estímulos, éstas cargan el cuerpo de la célula con señales eléctricas. El cuerpo de la célula, es el centro metabólico de ésta, es el que suma las señales de entrada y salida; mientras que el axón, es el encargado de distribuir la señal desde el cuerpo de la célula hacia otras neuronas. Por otro lado, se tiene la sinapsis, que es el punto de contacto entre el axón de una célula y la dendrita de otra [14].

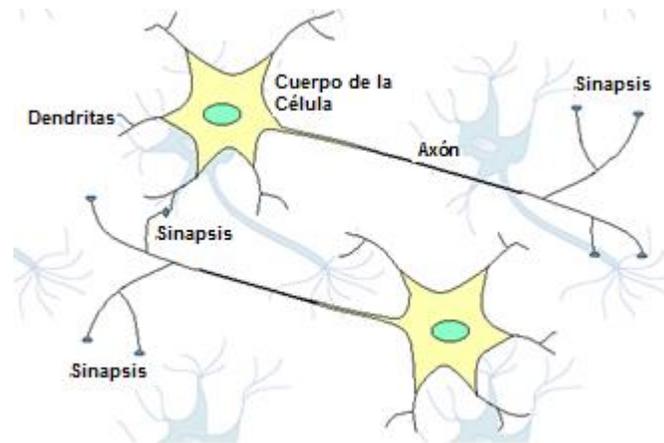


Figura 1.1. Estructura de la neurona. Tomado de [14].

### 1.3.2. Potencial de acción

El potencial de acción es el proceso mediante el cual el axón transmite una señal impulsiva, que consiste en una onda eléctrica autoregenerada, ésta puede ir desde una o varias células musculares, glandulares, nerviosas, etc. La amplitud máxima de un potencial de acción es de aproximadamente 100 mV, su duración está alrededor de un 1ms.

Para entender de una manera más clara el concepto de potencial de acción, se debe conocer la manera en que éste se genera. Inicialmente se tiene el potencial eléctrico<sup>6</sup>, el cual se produce debido al intercambio de iones dentro y fuera de la membrana de la neurona. El potencial en reposo<sup>7</sup> de una neurona oscila entre -60 y -70 mV, debido a que el valor de la carga eléctrica en la parte externa de la membrana plasmática ha sido establecida como 0. En una neurona el potencial de membrana<sup>8</sup> puede variar de una forma rápida y significativa, convirtiéndose en un mecanismo para transmitir señales. Estos

<sup>6</sup> Potencial eléctrico: el potencial eléctrico en un punto, es el trabajo que debe realizar una fuerza eléctrica para mover una carga positiva 'q' desde la referencia hasta ese punto, dividido por unidad de carga de prueba.

<sup>7</sup> Potencial en reposo: mientras una neurona no esté enviando una señal, se dice que está en "reposo". Al estar en reposo, su interior es negativo con relación al exterior.

<sup>8</sup> Potencial de membrana: es el resultado de la separación de cargas positivas y negativas a través de una membrana celular.



potenciales pueden cambiar como respuesta a la estimulación procedente de otras neuronas. Dependiendo de las variaciones, el potencial de membrana de las neuronas puede incrementar (hiperpolarización) o decrementar (despolarización). Para disparar un potencial de acción es necesario que el potencial de membrana alcance cierto umbral, a este umbral es posible acercarse mediante una despolarización, los estímulos que producen este cambio son excitatorios [15].

El potencial de acción en una neurona postsináptica<sup>9</sup> consiste en la suma de varios potenciales de acción que se encuentran alrededor de 20 a 30 mV. La señal detectada por un electroencefalograma corresponde a la suma de millones de potenciales postsinápticos excitatorios<sup>10</sup> e inhibitorios<sup>11</sup>, estos dos potenciales operan entre sí y dan lugar a las ondas cerebrales [16].

## 1.4. DESCRIPCIÓN ELÉCTRICA DE LAS SEÑALES EEG

Las señales EEG contienen el registro de la actividad eléctrica del cerebro, teniendo como punto de interés la amplitud de la señal. La amplitud de las señales EEG es baja al igual que la de otras señales electrofisiológicas, como las del Electrocardiograma para el corazón, Electromiografía para los músculos, Electrooculograma para los ojos, entre otras, pero con el uso de amplificadores diferenciales es posible amplificarlas y estudiarlas.

Las ondas del EEG tienen amplitudes que van hasta los 100  $\mu$ V cuando es sobre la superficie del cuero cabelludo, y entre 1-2 mV cuando es sobre la superficie del cerebro; estas ondas son de naturaleza aleatoria y aperiódica, ya que están cambiando constantemente sin mostrar ningún ciclo que se esté

---

<sup>9</sup> Neurona postsináptica: neurona receptora de la señal.

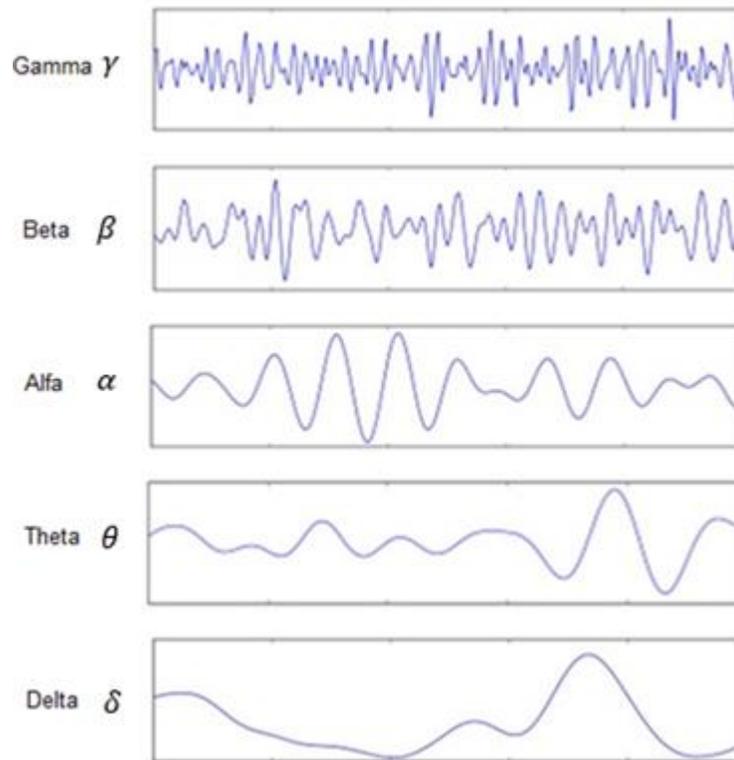
<sup>10</sup> Potenciales Postsinápticos excitadores: se da cuando la membrana es despolarizada y aumenta la probabilidad que se genere un potencial de acción

<sup>11</sup> Potenciales Postsinápticos inhibitorios: se da cuando se mantiene la neurona polarizada y disminuye la probabilidad que se genere un potencial de acción.



repitiendo en el tiempo. La frecuencia de las señales EEG esta entre 0,5 y 100 Hz, pero puede variar dependiendo del grado de actividad del córtex cerebral<sup>12</sup> [17].

Las señales de EEG no tienen una forma definida, algunas veces son *ritmos normales* u *ondas cerebrales*, que se pueden clasificar en delta  $\delta$ , theta  $\theta$ , alfa  $\alpha$ , beta  $\beta$  y gamma  $\gamma$  [18].



**Figura 1.2.** Ondas cerebrales típicas. Adaptada de [18].

<sup>12</sup> Córtex cerebral: la corteza cerebral es un tejido orgánico, también llamado sustancia gris, que recubre los dos hemisferios del cerebro y que tiene un grosor de unos pocos milímetros.



**Tabla 1.1.** Descripción de las ondas cerebrales típicas. Adaptada de [3].

CARACTERÍSTICAS	TIPO DE ONDAS CEREBRALES				
	Gamma $\gamma$	Beta $\beta$	Alfa $\alpha$	Theta $\theta$	Delta $\delta$
Rango de frecuencias (Hz)	>32Hz.	16Hz - 32Hz.	8 Hz - 16Hz.	4 Hz - 8Hz.	0 Hz - 4Hz.
Amplitud ( $\mu$ V)	Baja amplitud (No registra).	< 20 $\mu$ V.	< 15 $\mu$ V.	< 15 $\mu$ V.	> 75 $\mu$ V.
Localización donde se genera	Localización variable.	Región fronto-central.	Región occipital.	Región fronto-central.	Hemisferio derecho.
Estado de la persona	Vigilia.	Despierto, estado normal y alerta.	Relajado, calmado. Sin pensamiento.	Profunda relajación y meditación.	Sueño profundo.

Generalmente la onda  $\alpha$  es la única que debe presentarse en personas sanas cuando éstas empiezan a descansar, puesto que cuando se padece de epilepsia, aparecen las ondas  $\delta$  y  $\theta$  [3].

## 1.5. CAPTURA DE LAS SEÑALES EEG

El registro de las señales EEG cambia dependiendo de la ubicación de los electrodos y del sujeto sobre el cual se esté realizando la grabación, esta variación se debe a que se tiene un gran número de interconexiones que presentan las neuronas, y también por la forma no uniforme del encéfalo. Es importante resaltar que cuando una señal se registra, en este caso una EEG, posteriormente se debe procesar con el fin de eliminar el ruido tanto de bajas o altas frecuencias, o algún elemento que este perjudicando la obtención de los datos. Son muchos los factores que afectan una señal EEG debido a su



susceptibilidad a contaminaciones de ruido; entre estos factores se tiene el contacto del electrodo o la amplificación inapropiada, la cual puede provocar distorsión en el registro de una señal, otros factores serían la distancia a la que se ubiquen los electrodos y el tiempo de grabación.

Las señales que contienen la actividad bioeléctrica son nombradas de acuerdo a la manera en que se capturan, es decir, cuando se han utilizado electrodos sobre el cuero cabelludo conocidos como superficiales y electrodos en la base del cráneo conocidos como basales, a estos registros se les denomina Electroencefalograma (EEG). Cuando son electrodos quirúrgicos en la superficie de la corteza es Electrocorticograma (ECoG, *Electrocorticogram*) y si se usan electrodos quirúrgicos, pero de aplicación profunda, se denomina Estéreo Electroencefalograma (SEEG, *Stereo Electroencephalogram*) [19].

La ubicación de los electrodos es de suma importancia ya que a través de esto se capta información de ciertos sectores del cerebro. En el posicionamiento de los electrodos existen ciertas configuraciones entre las que se encuentra el sistema internacional 10-20, el cual se considera una de las configuraciones más comunes en cuanto al registro de las EEG y es uno de los más utilizados actualmente [17].

En el sistema internacional 10-20 se emplean 21 electrodos sobre la superficie del cuero cabelludo, como se puede visualizar en las figuras 1.3 y 1.4. Las posiciones de los electrodos se determinan teniendo como punto de referencia el *nación*, que es la parte superior de la nariz entre las cejas y el *inion*, que es la base del cráneo detrás de la cabeza. Teniendo en cuenta estos puntos de referencia, el perímetro del cráneo se mide en los planos transversales y medianos. Para localizar los electrodos, se deben realizar divisiones sobre estos perímetros en intervalos de 10% y 20% [17].

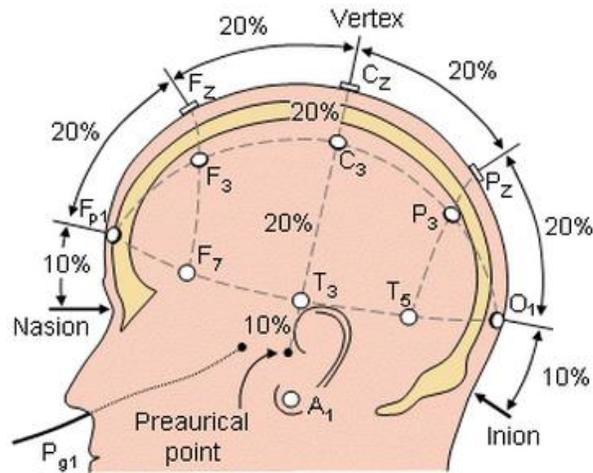


Figura 1.3. Vista de perfil. Tomado de [17].

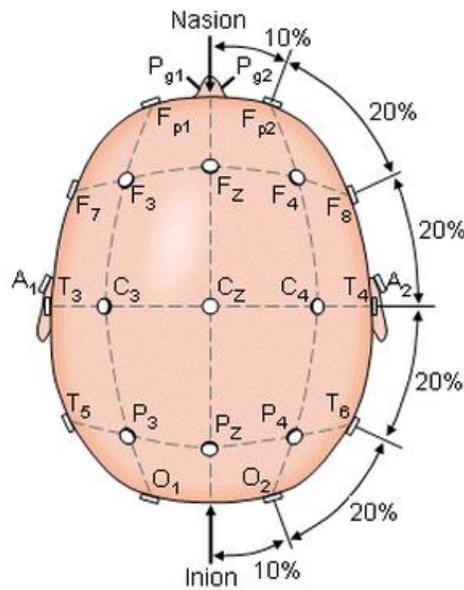
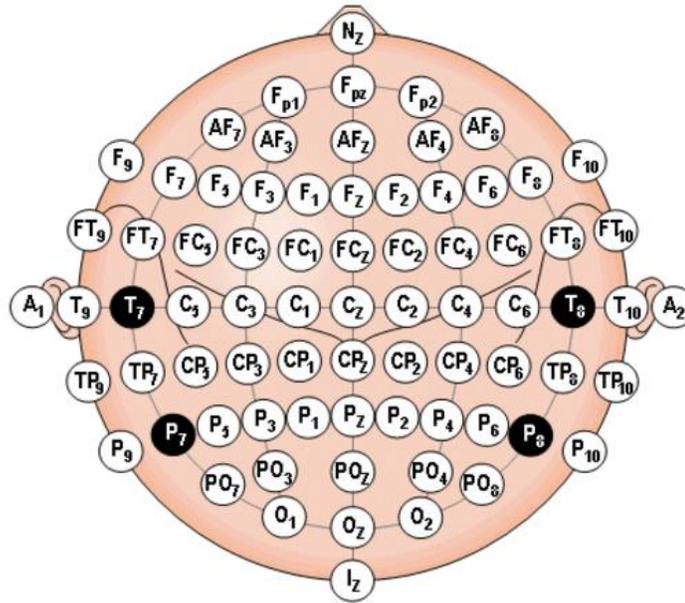


Figura 1.4. Vista superior. Tomado de [17].

La figura 1.5 muestra que además de los electrodos del sistema internacional 10-20, también se utilizan posiciones de los electrodos intermedios al 10%. Las ubicaciones y nomenclatura de estos electrodos están estandarizados por la Sociedad Americana de Electroencefalografía.



**Figura 1.5.** Ubicación y nomenclatura de los electrodos intermedios, estandarizada por la Sociedad Americana de Electroencefalografía. Tomado de [17].

La nomenclatura de los electrodos proporciona información de la ubicación de los mismos, la letra obedece a la región cerebral y el número que le sigue a ésta, señala el hemisferio, los números impares representan el lado izquierdo de este y los pares el derecho [15]. La tabla 1.2, lista la región cerebral en la que se localiza cada electrodo.



**Tabla 1.2.** Nomenclatura empleada en el sistema internación 10-20. Basada de [17].

Nomenclatura	Región cerebral
$F_{P1} - F_{P2}$	Frontopolar o Prefrontal
$F_3 - F_4$	Mediofrontal
$F_7 - F_8$	Frontal o temporal inferior
$C_3 - C_4$	Central
$P_3 - P_4$	Parietal
$O_1 - O_2$	Occipital
$T_3 - T_4$	Temporal medial
$T_5 - T_6$	Temporal posterior
$F_Z - C_Z - P_Z$	Frontal, Central y Parietal
$A_1 - A_2$	Mastoides o Pabellones Auriculares

### 1.5.1. Consideraciones de ruido

Las señales electrofisiológicas tienen un proceso para su obtención, en el caso de las EEG estas se producen bioeléctricamente o por excitación celular, pero también a través de campos eléctricos que se crean en torno a los electrodos. El registro del EEG es susceptible a diversas formas y fuentes de ruido, lo cual produce problemas en el posterior análisis e interpretación de la señal. En el proceso de adquisición de las señales biológicas se está expuesto a factores como la distorsión, ruido térmico, interferencia electromagnética o movimientos de los pacientes; en el caso de los campos eléctricos generados alrededor de los electrodos se presenta el ruido eléctrico. La contaminación de ruido eléctrico puede ser producto de algún componente que posea un campo eléctrico ya sea un computador, un transformador e inclusive el amplificador de la señal EEG [20].



Existen algunas fuentes de las cuales puede provenir el ruido, la primera fuente sería por el contacto de los electrodos sobre el cuero cabelludo y la segunda debido a la conexión de los cables del electrodo al amplificador. Otra fuente de ruido en las grabaciones EEG es el fisiológico el cual puede ser causado por varios generadores de ruido, los ejemplos más comunes de este son la frecuencia cardiaca Electrocardiograma (ECG, *electrocardiogram*), artefactos de movimiento causados por la contracción muscular Electromiograma (EMG, *electromyogram*) y las señales oculares causadas por el movimiento del globo ocular Electrooculograma (EOG, *electrooculogram*), de estas tres señales la única imposible de evitar es la ECG. La cuarta fuente de generación de ruido son los dispositivos de grabación, el movimiento de aparatos, líneas de alimentación AC, la iluminación, elementos electrónicos (Computador, ordenadores portátiles y móviles, entre otros) [21].

Uno de los más grandes desafíos del uso de EEG, es la pequeña relación señal-ruido de las señales cerebrales; sin embargo, se tiene un gran número de estrategias para hacer frente al ruido de manera efectiva, esto tanto en el periodo de la grabación de EEG, así como durante el pre-procesamiento de los datos registrados.





## CAPÍTULO 2

# PROCESAMIENTO DIGITAL DE UNA SEÑAL EEG PARA SU CLASIFICACIÓN

El procesamiento digital de señales EEG busca adecuar la señal, bien sea para reducción de ruido e interferencias, amplificación, compresión, clasificación, entre otros. En el presente trabajo de grado se aplica la teoría wavelet en el análisis de señales EEG, se exploran las técnicas de extracción de características temporales, y espectrales basadas en wavelet, para formar vectores descriptores simples<sup>13</sup> e híbridos<sup>14</sup>, que realicen de manera eficiente la clasificación de patrones EEGs.

La figura 2.1, muestra las fases de procesamiento de señales EEG con registros de epilepsia para propósitos de detección de estados normal, ictal y postictal.

---

<sup>13</sup> Vectores de descripción simples: vector conformado por características extraídas de la señal, aplicando una sola técnica, éstas pueden ser en el dominio temporal o espectral.

<sup>14</sup> Vectores de descripción híbridos: vector conformado por la combinación de características extraídas de la señal, esto tanto en el dominio temporal y espectral.

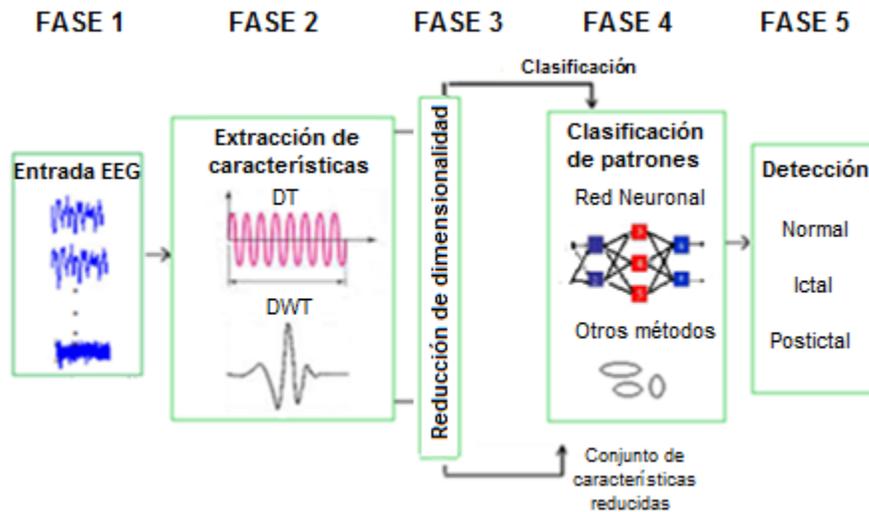


Figura 2.1. Detección de las señales EEG. Adaptada de [22].

- **Fase 1. Entrada EEG:** consiste en la recolección de la señal, que contiene la información captada mediante electrodos ubicados sobre el cuero cabelludo del paciente. Las señales utilizadas en el presente trabajo de grado se obtuvieron de una base de datos del Instituto Tecnológico de Massachusetts (MIT, *Massachusetts Institute of Technology*), disponible en: [physionet.org](http://physionet.org) [23].

La base de datos CHB-MIT fue generada en el hospital de niños de Boston, está compuesta de registros EEG de 22 personas, 5 hombres con edades comprendidas entre los 3 y 22 años y 17 mujeres entre 1,5 y 19 años, estas personas fueron monitoreadas días después de que la medicación contra las convulsiones epilépticas fuera retirada, con el fin de caracterizarlas y verificar que tan factible era una intervención quirúrgica, ya que sufrían convulsiones intratables. Los registros contienen aproximadamente una hora de grabación agrupados en diferentes canales. La información de cada uno es recolectada por medio de electrodos ubicados sobre el cuero cabelludo, según el sistema internacional 10-20. La frecuencia de muestreo es de 256 Hz [23] [24].

Para este trabajo se utilizan 10 registros de señales EEG, cinco (5) para propósitos de entrenamiento y cinco (5) para prueba de detección y clasificación de 3 estados (normal, ictal y postictal).



- **Fase 2. Extracción de características:** se adquiere un conjunto de parámetros con la información más relevante de la señal captada por los electrodos. Entre las técnicas de extracción de características, la que más se destaca por su simplicidad, gracias a que no necesita de transformación sobre la señal, es la basada en el análisis temporal. Posteriormente surgen técnicas de análisis espectral, como la Transformada de Fourier (FT, *Fourier Transform*). Sin embargo, debido a la naturaleza aleatoria y no estacionaria de las señales EEGs, la Transformada de Fourier no resulta ser la más apropiada para este análisis, es por esto, que se recurre a la teoría de wavelet con la Transformada Wavelet Discreta, que permite un análisis de la señal en el dominio de tiempo y frecuencia de manera simultánea [6].
- **Fase 3. Reducción de dimensionalidad:** se optimiza el conjunto de características extraídas, asegurando que la información más importante se conserve. Las principales técnicas que se han utilizado para conseguir la reducción del conjunto de características, tienen como finalidad mejorar la eficiencia sin disminuir la precisión del clasificador y reducir la carga computacional.
- **Fase 4. Clasificación de patrones:** se evalúan las fases de extracción de características y de reducción de dimensionalidad en la conformación de los vectores descriptores, que tienen como finalidad la clasificación de señales EEGs; para esto se someten estos vectores al proceso de clasificación de patrones.
- **Fase 5. Detección:** como resultado de la clasificación se obtiene la detección o determinación de los estados normal, ictal y postictal.



## 2.1. EXTRACCIÓN DE CARACTERÍSTICAS

La fase de extracción de características es de suma importancia, ya que ésta es determinante para realizar una buena clasificación de estados y consiste básicamente en alcanzar una apropiada caracterización de las señales. La fase de extracción de características, es posible llevarla a cabo a través de dos dominios de la señal: temporal y espectral. El Dominio Temporal (DT, *Domain Time*) de la señal se realiza a partir de sus parámetros estadísticos y el dominio espectral mediante transformaciones como la WT.

Es necesario conocer algunos conceptos básicos que ayudarán a comprender el proceso de extracción de características [25]:

- *Muestras o datos*: objeto de estudio para reconocimiento y/o clasificación.
- *Característica*: medida o atributo que se utiliza para caracterizar un patrón.
- *Patrón*: es la representación cuantitativa de un objeto, mediante un vector descriptor  $\mathbf{x}$  de  $N$  características ( $x_i, i = 1, 2, \dots, N$ ).
- *Clase*: es una categoría a la que pertenece un patrón.
- *Función discriminante*: relación que permite la clasificación de patrones.

Se debe tener en cuenta, que no es adecuado formar directamente un vector descriptor  $\mathbf{x}$  sobre el espacio original de las características, debido a:

1. La gran dimensión del espacio de la señal de entrada.



2. El ruido, ya que al estar presente en los registros de las señales EEG, podría causar problemas al momento de realizar el proceso de clasificación.
  
3. Redundancia de la información en el espacio original de la señal.

Con el fin de mitigar los tres aspectos anteriores, es recomendable extraer del espacio original de la señal,  $R^N$ , un conjunto de características que forman un vector descriptor  $\mathbf{v} \in V \subseteq R^M$ , de menor tamaño, es decir  $M \leq N$ . En caso de que la fase anterior  $R^M$  siga teniendo una dimensión muy grande, se procede a implementar una fase de reducción de dimensionalidad, la cual consiste en extraer características mínimas necesarias en un vector  $\mathbf{z} \in Z \subseteq R^L$ , es decir  $L < M$ . Lo que se pretende lograr con la fase anterior, es disminuir la carga computacional y obtener un buen desempeño del clasificador [26].

A continuación, se describen las dos técnicas utilizadas para extraer las características de la señal EEG.

### 2.1.1. Análisis temporal

A una secuencia de valores que se observan a lo largo del tiempo, las cuales están ordenados cronológicamente, se les conoce como serie temporal. Las características en el dominio del tiempo pueden ser calculadas rápidamente, y esto se debe a que no requieren ninguna transformación sobre la señal.

Las características temporales aplicadas con mayor frecuencia a las señales EEG, han sido ampliamente investigadas y utilizadas en los trabajos referenciados en [25], [27-31] y son las siguientes<sup>15</sup>:

---

<sup>15</sup> Para este documento todas las medidas serán insesgadas es decir todos los datos son probables. El insesgamiento no hace una estimación a nivel estadístico.



- **Media:** ésta es una medida de tendencia central, en la que se realiza la sumatoria de todos los valores de una muestra y se divide por el número de valores totales. Matemáticamente se puede expresar mediante la ecuación (2.1) [32].

$$\bar{x} = \frac{\sum_{i=1}^N x_i}{N}, \quad (2.1)$$

donde  $x_i$  representa cada uno de los valores de la muestra y  $N$  es el número total de muestras.

- **Varianza:** está definida como la media aritmética del cuadrado de las desviaciones respecto a la media de una distribución estadística, se expresa como:

$$\sigma^2 = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N - 1}, \quad (2.2)$$

donde  $\bar{x}$  representa la media de los datos

- **Desviación Estándar:** corresponde a la raíz cuadrada de la varianza [33]:

$$\sigma = \left[ \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N - 1} \right]^{1/2}. \quad (2.3)$$

- **Asimetría:** es una medida de forma. Mide la distribución simétrica y continua alrededor de la media  $\bar{x}$ . Esta medición da lugar a los coeficientes de asimetría expresados como [33]:

$$\gamma = \frac{\sum_{i=1}^N (x_i - \bar{x})^3}{N\sigma^3}, \quad (2.4)$$



donde  $\sigma$  representa la desviación estándar de los datos.

- **Curtosis:** es una medida de la forma. Mide la mayor o menor concentración de datos alrededor de la media. La función de densidad de su centro se puede expresar como [33]:

$$K = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{N\sigma^4}. \quad (2.5)$$

- **Coefficiente de variación:** éste se utiliza para hacer referencia a la relación entre la desviación típica de una muestra y su media, se expresa así [32]:

$$CV = \frac{\sigma}{\bar{x}}. \quad (2.6)$$

- **Valor Medio Absoluto (VMA):** evalúa  $\bar{X}_l$  que corresponde al valor medio absoluto, esto lo realiza sobre cada segmento  $l$  de  $N$  muestras de longitud de la señal. VMA puede ser expresado de la siguiente forma [31]:

$$\bar{X}_l = \frac{1}{N} \sum_{k=1}^N |x_k|, \quad l = 1, 2, \dots, L, \quad (2.7)$$

donde  $x_k$  es la  $K^{ésima}$  muestra en el segmento  $l$ , y  $L$  es el número total de segmentos.

- **Cruces por Cero (CC):** éste se calcula realizando el conteo del número de veces que la forma de onda cruza por cero, siendo esta una manera sencilla de obtener la frecuencia de la señal. Con el fin de disminuir el número de cruces por cero a consecuencia del ruido, se debe elegir un umbral, el cual se selecciona a partir del voltaje máximo de la señal (valor típico es 0.01 del valor pico de la señal). Al considerar dos



muestra consecutivas  $x_k$  y  $x_{k+1}$ , la cantidad de cruces por cero aumenta en 1 unidad si se satisfacen las siguiente condiciones [31]:

$$(x_k)(x_{k+1}) < 0. \quad (2.8a)$$

$$|x_k - x_{k+1}| \geq 0.01V. \quad (2.8b)$$

- **Cambio de Signo de Pendiente (CSP):** esta característica permite, a través del número de veces que cambia la pendiente de una señal, medir la frecuencia de ésta. Así como en la característica anterior, es recomendable seleccionar un umbral que reduzca los cambios de pendiente que se generan por el ruido. La cantidad de cambios de signo de pendiente aumenta en 1 unidad si se satisfacen las siguientes condiciones [31]:

$$(x_k > x_{k-1} \wedge x_k > x_{k+1}) \vee (x_k < x_{k-1} \wedge x_k < x_{k+1}). \quad (2.9a)$$

$$|x_k - x_{k+1}| \geq 0.01V \quad \vee \quad |x_k - x_{k-1}| \geq 0.01V. \quad (2.9b)$$

- **Longitud de la forma de Onda (LO):** esta característica brinda información de la complejidad de la forma de onda en cada segmento, la cual, para cada segmento de N muestras, se obtiene de la siguiente manera [31]:

$$LO = \sum_{k=1}^N |\Delta x_k|, \quad (2.10)$$

donde  $\Delta x_k = x_k - x_{k-1}$  (diferencia entre valores de muestras consecutivas). El resultado obtenido da una idea acerca de cómo es la amplitud, la frecuencia y la duración de la onda.



## 2.1.2. Análisis espectral con Wavelet

- **Transformada wavelet**

El propósito de cualquier transformada es representar una señal del tiempo en un dominio alterno, en el cual se adviertan detalles o características difíciles de identificar en el dominio temporal. Específicamente, la transformada wavelet lleva la información de la señal al plano escala-traslación, donde la escala está emparentada con la frecuencia y la traslación con el tiempo. En ese sentido, la transformada wavelet, a diferencia de la transformada de Fourier, permite conocer los instantes del tiempo en los cuales se producen ciertas componentes de frecuencia.

La Transformada Wavelet se divide en diferentes tipos, entre estos se tiene la Transformada Wavelet Continua (CWT, *Continuous Wavelet Transform*), la Transformada Wavelet Discreta (DWT, *Discrete Wavelet Transform*) y la Transformada de Paquetes Wavelet (WPT, *Wavelet Packet Transform*). En el presente trabajo se empleó la DWT.

A continuación, se presenta una descripción de la Transformada Wavelet Discreta.

- **Transformada Wavelet Discreta**

La Transformada Wavelet Discreta se basa en la Transformada Wavelet Continua. La CWT representa una señal  $x(t)$  continua en el tiempo, como una expansión de términos o coeficientes proporcionales al producto interno, entre la señal y diferentes versiones escaladas y trasladadas de una función  $\psi(t)$  llamada *wavelet madre*. Teniendo en cuenta que tanto la señal  $x(t)$  como la función  $\psi(t)$  son de energía finita, entonces se tiene [34] [35]:



$$CWT(a,b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt; \quad a,b \in R; a \neq 0. \quad (2.11)$$

Para fines prácticos conviene discretizar la transformada CWT, y para esto se asignan valores discretos a las variables de escala  $a$  y traslación  $b$ , es así como aparece la Transformada Wavelet Discreta. En la ecuación (2.12), se observa como se discretiza las variables de escala y traslación, a través de una escala diádica [34]:

$$\begin{aligned} a &= 2^{-j}, \\ b &= 2^{-j}k, \end{aligned} \quad (2.12)$$

donde  $j, k \in Z$ .

La Transformada Wavelet Discreta, elimina en gran parte la redundancia que se presenta en la Transformada Continua. Por otra parte, se tiene que al discretizar los parámetros de esta manera es posible una reconstrucción perfecta (usando una familia de wavelet ortogonal)<sup>16</sup>; además de lograr mayor eficiencia computacional y una representación de la señal más compacta, por lo anterior la DWT tiene un mayor uso que la CWT. Los parámetros  $j$  y  $k$  se conocen como nivel de resolución (compresión o dilatación) y nivel de traslación (desplazamiento) respectivamente; también, se puede apreciar como el parámetro de escala depende del nivel de resolución y el parámetro de traslación depende tanto de  $j$  como de  $k$ , con esto se tiene que los parámetros ' $a$ ' y ' $b$ ' no son independientes [36].

Con lo anterior se puede deducir que el conjunto de funciones wavelet:

---

<sup>16</sup> Familia wavelet ortogonal: es un conjunto de wavelets, tales que el producto interno entre cualquier par de ellos siempre va a dar cero.



$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right); \quad a, b \in R, \quad (2.13)$$

se redefine de la forma:

$$\psi_{j,k}(t) = 2^{\frac{j}{2}} \psi(2^j t - k); \quad j, k \in Z, \quad (2.14)$$

En la ecuación (2.14), se tiene el conjunto de funciones conocidas como *versión diádica discreta* de la función *wavelet* o *conjunto de expansión wavelet*, la cual forma una *base*<sup>17</sup> *ortonormal* de  $L^2(R)$ . Por otra parte, se tiene el factor  $2^{\frac{j}{2}}$  que es indispensable para cumplir con la condición de ortonormalidad<sup>18</sup>, a este factor se le conoce como constante de normalización [34]. Con esto se tiene que las bases wavelets hacen posible la descomposición ortogonal de funciones en  $L^2(R)$ .

$$L^2(R) = \bigoplus_j \Omega_{j,1}, \quad (2.15)$$

donde  $\bigoplus_j$  es un conjunto o colección de funciones de  $\Omega_{j,1}$  y  $\Omega_{j,1}$  corresponde al subespacio originado por  $\{\psi_{j,k}\}_{k \in Z}$

En los sistemas wavelet, la wavelet madre  $\psi(t)$  tiene vinculada una función de escala  $\phi(t)$  y se representa así [34]:

$$\phi_{j,k}(t) = 2^{\frac{j}{2}} \phi(2^j t - k), \quad j, k \in Z, \quad (2.16)$$

---

<sup>17</sup> Base: es un conjunto de funciones o vectores, de tal manera que cualquier elemento del espacio vectorial en cuestión, se puede obtener como una combinación lineal de los elementos de la base.

<sup>18</sup>Ortonormalidad: es un conjunto ortogonal con la particularidad que la norma (energía) de todos los elementos del conjunto es igual a uno.



La función escala origina una base ortonormal de  $L^2(R)$ , con lo que se tiene que las bases escala al igual que las wavelets, hacen posible la descomposición ortogonal de funciones en  $L^2(R)$ :

$$L^2(R) = \bigoplus_j \Omega_{j,0}, \quad (2.17)$$

donde  $\bigoplus_j$  es un conjunto o colección de funciones de  $\Omega_{j,0}$  y  $\Omega_{j,0}$  corresponde al subespacio originado por  $\{\phi_{j,k}\}_{k \in Z}$ .

De esta forma una función  $x(t) \in L^2(R)$ , es posible aproximarla utilizando una o ambas funciones (función escala y función wavelet). Esta aproximación se puede expresar de la siguiente forma [34]:

$$x(t) = \sum_k \sum_j c_{j,k} \phi_{j,k}(t) + \sum_k \sum_j d_{j,k} \psi_{j,k}(t); \quad j, k \in Z, \quad (2.18)$$

En la ecuación (2.18) se puede observar dos variables  $c_{j,k}$  y  $d_{j,k}$ , las cuales representan los coeficientes de “aproximaciones” y de “detalles” respectivamente, en la descomposición wavelet DWT de la señal. Para obtener estos coeficientes se realizan etapas de filtrado continuo utilizando bancos de filtros pasa-altas y pasa-bajas [35].

Se tiene que la función escala  $\phi(t)$  conlleva a una cadena de subespacios anidados, así:

$$\Omega_{J,0} \subset \Omega_{J-1,0} \subset \dots \subset \Omega_{1,0} \subset \Omega_{0,0}. \quad (2.19)$$

La naturaleza de la función escala es que una proyección de la señal original  $x(t)$  en el espacio  $\Omega_{j,0}$ , es una operación de *paso-bajas*, es decir una *aproximación* de  $x(t)$  a escala  $a = 2^j$ , como se puede observar a continuación:



$$C_j[n] = \langle x(t), \phi_{j,k}(t) \rangle = \int_{-\infty}^{\infty} x(t), \phi_{j,k}(t) dt . \quad (2.20)$$

$\Omega_{0,0}$  (escala  $a = 2^0$ ) es el espacio de la señal original  $x(t)$ .

En el caso de la componente de detalle de  $x(t)$  a escala  $a = 2^j$ , que equivale a una operación pasa-banda, toma la forma:

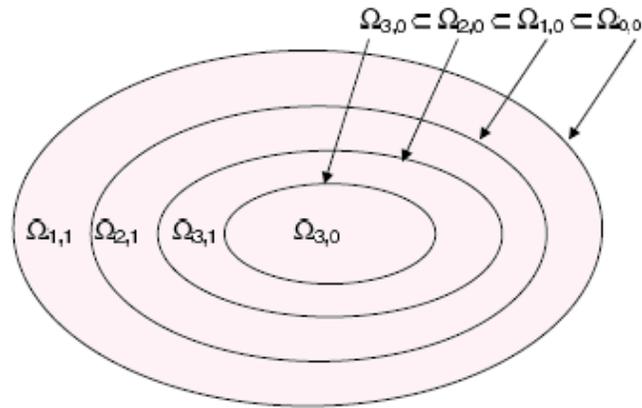
$$D_j[n] = \langle x(t), \psi_{j,k}(t) \rangle = \int_{-\infty}^{\infty} x(t), \psi_{j,k}(t) dt . \quad (2.21)$$

La función wavelet y escala originan espacios anidados que se relacionan de la siguiente manera:

$$\Omega_{j,0} = \Omega_{j+1,0} \oplus \Omega_{j+1,1} \quad \text{para } j = 0, 1, \dots, J . \quad (2.22)$$

Con lo anterior, se tiene que el espacio  $\Omega_{j+1,1}$  posee el detalle suficiente para ir de una aproximación  $\Omega_{j+1,0}$ , a un nivel de aproximación más fino  $\Omega_{j,0}$ .

La DWT es una manera de mostrar el espacio  $\Omega_{0,0}$ , a través de la suma directa de subespacios ortogonales, como se ilustra en la figura 2.2.



**Figura 2.2.** Anidamiento de subespacios wavelets  $\Omega_{j,1}$  y escalas  $\Omega_{j,0}$  para  $J = 3$ .

Adaptada de [34].

Se concluye que la DWT realiza el análisis de una señal por medio de la descomposición en sucesivas señales de aproximaciones  $C_j[n] \in \Omega_{j,0}$  y detalles  $D_j[n] \in \Omega_{j,1}$ . Por lo tanto, se tiene que a través de secuencias de coeficientes wavelets, es posible representar un estudio integral de una señal original  $x[n]$ :

$$\mathbf{D} = \{D_1[n], D_2[n], \dots, D_J[n], C_J[n]\}. \quad (2.23)$$

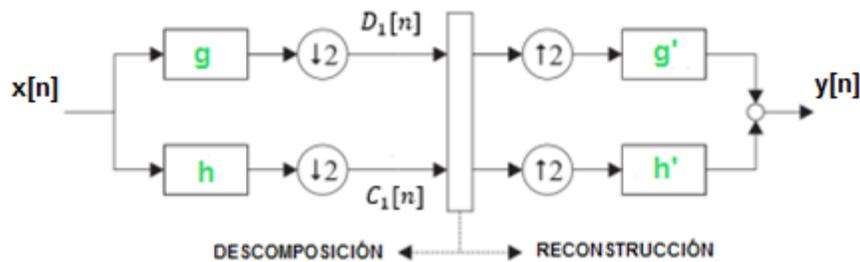
De la ecuación (2.23), se puede deducir que los coeficientes que se obtienen de la DWT cuando se descompone a un nivel  $J$  son:  $J$  niveles de coeficientes de *detalles* y un nivel  $J^{\text{ésimo}}$  de coeficientes de *aproximaciones*. Por ejemplo, para un nivel de descomposición  $J = 3$  se tienen 3 niveles de coeficientes de *detalles* ( $D_1, D_2, D_3$ ) y 1 nivel de aproximación ( $C_3$ ).



- **Análisis DWT utilizando Bancos de Filtros.**

Una señal es posible descomponerla en diferentes niveles, esto mediante el Análisis Multiresolución (MRA, *Multiresolution Analysis*)<sup>19</sup> de la DWT. Dentro de cada nivel se utiliza un par de filtros (pasa-altas y pasa-bajas) que corta el dominio de la frecuencia a la mitad. Para el proceso de multiresolución se comienza dividiendo la señal original en coeficientes de aproximación  $C_j$  y de detalle  $D_j$ . Después, los coeficientes de aproximación son nuevamente divididos en nuevos coeficientes de aproximación y detalle. Se sigue realizando lo anterior hasta obtener el conjunto de aproximación y detalle para el nivel de resolución requerido [5].

Las operaciones de filtrado y los cambios de escala juegan un papel importante a la hora de determinar la resolución de una señal, los cambios de escala se pueden definir mediante las operaciones de *downsampling* y *upsampling*. La primera se utiliza en la fase de la descomposición de la señal, esta consiste en eliminar el valor de la muestra intercaladamente, es decir, si se tiene  $x = [20\ 20\ 30\ 40]$  y se aplica downsampling, se obtiene  $x = [20\ 40]$ . La segunda operación se usa en la fase de síntesis, aquí se agrega 0 entre cada elemento del conjunto, es decir, si se toma la salida del ejemplo anterior y se aplica upsampling se tendría  $x = [0\ 20\ 0\ 40\ 0]$  [5].



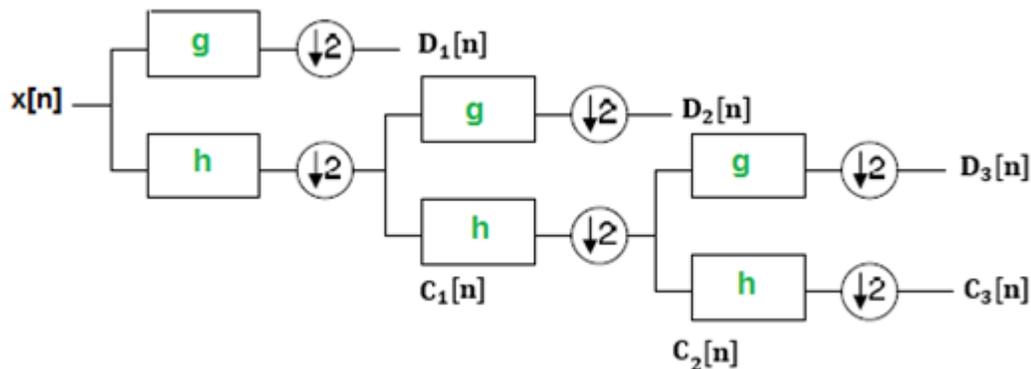
**Figura 2.3.** Estructura DWT a un nivel ( $J = 1$ ). Adaptada de [5].

<sup>19</sup> MRA: consiste en multiplicar la señal por funciones ventana de diferentes escalas o resoluciones llamadas wavelets.



En la figura 2.3 se muestra la descomposición y síntesis de la DWT a un nivel; la señal original  $x[n]$  es sometida a un filtro pasa altas  $g[n]$  y pasa bajas  $h[n]$ , seguido de un proceso de *downsampling*  $\downarrow 2$  y *upsampling*  $\uparrow 2$ . Finalmente se tiene un par de filtros pasa altas  $g'[n]$  y pasa bajas  $h'[n]$  para la reconstrucción de la señal  $y[n]$ .

A continuación, se muestra el proceso de descomposición DWT para  $J = 3$



**Figura 2.4.** Proceso de transformación discreta de wavelets para  $J = 3$ . Adaptada de [37].

En la figura 2.4, se observa que por medio de filtros pasa bajos  $h[n]$  se obtienen los coeficientes  $c_j$ , que son las aproximaciones de la señal y con los filtros pasa altos  $g[n]$  se obtienen los detalles  $d_j$ . Si  $x[n]$  es la señal a ser analizada de longitud  $N$  muestras, se tiene que al realizar la primera descomposición DWT se obtendrán los coeficientes  $D_1[n]$  y  $C_1[n]$  de longitud  $N/2$ . Para obtener la descomposición a dos niveles se aplica el proceso anterior a la banda de frecuencias bajas, obteniéndose de esta manera los coeficientes  $D_2[n]$  y  $C_2[n]$  de longitud  $N/4$ , todo este proceso es posible repetirlo hasta  $j \leq \log_2 N$  veces. Por ejemplo, si se tiene 1024 muestras, el nivel máximo de descomposición es 10 [37].

Generalmente el proceso de descomposición se lleva al máximo de profundidad, aunque la descomposición podría terminar en cualquier nivel, lo cual quiere decir que la división de frecuencias en torno a un rango de bajas



frecuencias puede detenerse, esto sería conveniente si la subbanda pertenece a una escala que no entrega componentes de energía significativa.

Al proceso de filtrado y diezmado sucesivo se le conoce como codificación en subbandas. Dicha operación se expresa de la siguiente forma:

$$x_{altas}[k] = \sum_n x[n]g[2k - n] \quad n = 0, 1, \dots, N - 1, \quad (2.24)$$

$$x_{bajas}[k] = \sum_n x[n]h[2k - n], \quad n = 0, 1, \dots, N - 1. \quad (2.25)$$

- **Aplicación de la DWT**

A continuación se realiza una descomposición correspondiente a una señal EEG, esto se hace con el fin de explicar a través de un ejemplo la teoría de la DWT. La señal EEG cuenta con 256 muestras y el nivel de descomposición es de 5.

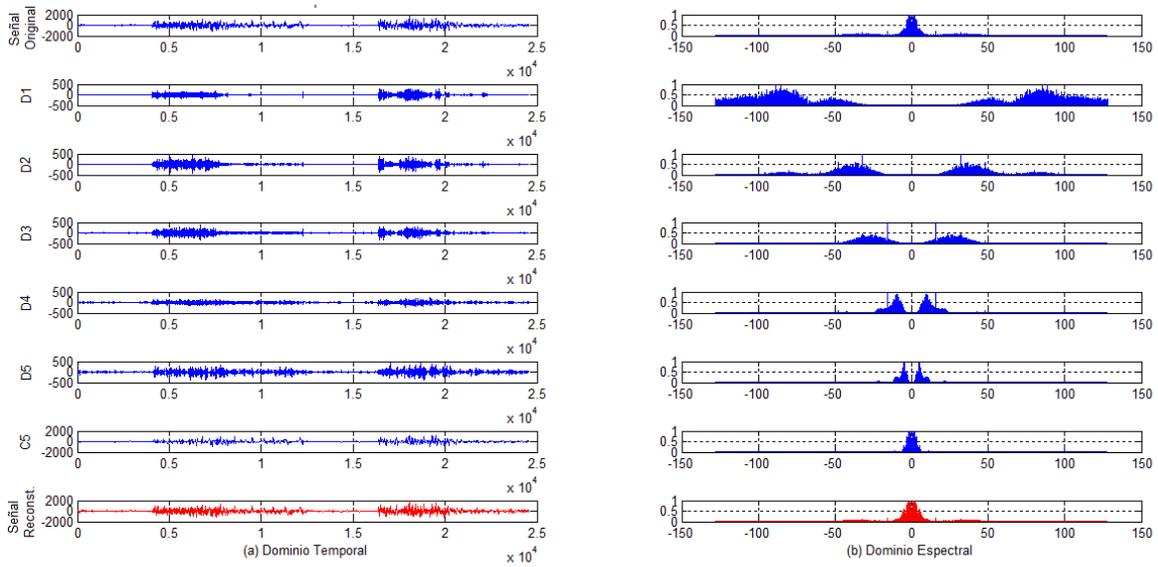


Figura 2.5. Descomposición y reconstrucción DWT a nivel 5 de una señal EEG.

Como se observa en la figura 2.5 (a), inicialmente se muestra la señal original en el dominio del tiempo; posteriormente los detalles de ésta, los cuales se denotan de D1 a D5 y las aproximaciones C5; por último se tiene la señal reconstruida (color rojo), que se obtiene con la suma de las descomposiciones wavelet. En la figura 2.5 (b), se ilustra la señal original en el dominio espectral; luego, se observan las subbandas correspondientes a la descomposición a nivel 5. D1 contiene el rango de frecuencias de ruido, D2 de las ondas gamma, D3 de las beta, D4 de las alfa, D5 de las theta y C5 de las delta. Finalmente se tiene la señal reconstruida (color rojo).

Cabe resaltar que el criterio de Nyquist se cumple, ya que la señal EEG utilizada para el análisis de la DWT, maneja un rango de frecuencia entre 0-128 Hz y su frecuencia de muestreo es 256 Hz.

### 2.1.3. Extracción de características basadas en wavelets.

Para extraer características discriminantes cuya información esté en el plano tiempo-frecuencia, se realiza un análisis tempo-espectral mediante la DWT;



análisis adecuado para las señales EEG, debido a que son señales aleatorias no estacionarias. El método empleado para la extracción de características es el de *evaluación de parámetros*, que consiste en calcular el valor numérico de parámetros como: Descomposición en Valores Singulares (SVD, *Singular Value Decomposition*), Energía de escala, Promedio absoluto de coeficientes, el máximo en escala, varianza, Entropía aproximada, Entropía muestral y Entropía espectral. Estos han sido ampliamente utilizados en señales EEG, en los trabajos referenciados en [38-41], y se explican a continuación:

- **Descomposición en Valores Singulares:** es la raíz cuadrada de los valores propios o autovalores de la matriz  $C^T C$ , matemáticamente se representa así:

$$SVD = \sqrt{\lambda(C^T C)}, \quad (2.26)$$

donde  $C$  representa una matriz con filas formadas por las subbandas de coeficientes wavelets, y  $\lambda$  son los autovalores de  $C^T C$ .

- **Energía de escala:**

$$ENER_j = \frac{1}{2} \sum_k c_{jk}^2, \quad (2.27)$$

donde  $c_{jk}$  es el  $k$ -ésimo coeficiente escala del nivel  $j$ -ésimo.

- **El promedio absoluto de coeficientes:** es la media normalizada, se representa así:

$$AVG_j = \frac{1}{K} \sum_{k=1}^K |c_{jk}|, \quad (2.28)$$

donde  $c_{jk}$  es el  $k$ -ésimo coeficiente escala del nivel  $j$ -ésimo, y  $K$  el



número total de coeficientes.

- **El máximo en la escala:** es el máximo absoluto de los coeficientes de la escala, esta definido como:

$$MAX_j = \max_j(|c_{jk}|), \quad (2.29)$$

donde  $c_{jk}$  es el  $k$ -ésimo coeficiente la escala del nivel  $j$ -ésimo.

- **Varianza (VAR):** esta característica sirve para cuantificar el grado de dispersión cuadrática de los datos respecto a la media. Se calcula por medio de la siguiente ecuación.

$$VAR_j = \frac{1}{K} \sum_{k=1}^K (c_{jk} - \bar{c}_{jk})^2, \quad (2.30)$$

donde  $c_{jk}$  es el  $k$ -ésimo coeficiente de la escala del nivel  $j$ -ésimo, y  $K$  el número total de coeficientes.

- **Entropía Aproximada:** es la probabilidad logarítmica de que las tendencias de los patrones de datos que están cerca uno del otro, permanezcan así en la próxima comparación con el siguiente patrón. Entropía Aproximada, es una medida de regularidad de los datos y se calcula así [42]:

$$ApEn(m, r, N) = \phi^m(r) - \phi^{m+1}(r), \quad (2.31)$$

donde  $\phi^m(r)$  esta dada por:

$$\phi^m(r) = \frac{1}{(N - m + 1)} \sum_{i=1}^{N-m+1} \log [C_i^m(r)], \quad (2.32)$$



donde  $N$  corresponde a la longitud de la ventana (muestras),  $m$  es el número de muestras previas usadas para la predicción de la muestra siguiente,  $r$  es un parámetro fijo que establece la tolerancia de la comparación y está comprendido entre 0.1 y 0.25 veces la desviación estándar de la señal original,  $C_i^m(r)$  la probabilidad de que un vector  $u_m(j)$  se encuentre cercano a un vector  $u_m(i)$ .

La probabilidad  $C_i^m(r)$  se evalúa dividiendo el número de vectores  $u_m(j)$ , con  $1 \leq j \leq N - m + 1$  tales que  $d[u_m(i), u_m(j)] \leq r$ , por el número de vectores extraídos en la serie de tiempo. Así para  $1 \leq i \leq N - m + 1$

$$C_i^m(r) = \frac{(\text{número de } j \text{ tales que } d[u_m(i), u_m(j)] \leq r)}{(N - m + 1)}. \quad (2.33)$$

Los valores de  $C_i^m(r)$  miden la regularidad o frecuencia, de valores similares dado la longitud  $m$  dentro de la tolerancia  $r$ .

- **Entropía Muestral:** corresponde al negativo del logaritmo natural de la probabilidad condicional de las secuencias cercanas para  $m$  puntos consecutivos. Una de las ventajas de esta entropía frente a la aproximada, es que es menos dependiente del tamaño de la serie de tiempo, se define como [42]:

$$\text{SampEn}(m, r, N) = -\ln \frac{U^{m+1}(r)}{U^m(r)}, \quad (2.34)$$

donde  $U^m(r)$  y  $U^{m+1}(r)$  están dadas por:

$$U^m(r) = \frac{1}{N - m} \sum_{i=1}^{N-m} C_i^m(r), \quad (2.35)$$



$$U^{m+1}(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} C_i^{m+1}(r). \quad (2.36)$$

$U^m(r)$  y  $U^{m+1}(r)$  determinan los elementos de la SampEn mediante el número de parejas  $[u_m(i), u_m(j)]$  que cumplen con el parámetro  $r$ , tal que  $d[u_m(i), u_m(j)] \leq r$  tal que  $i \neq j$ , es decir, no se tiene en cuenta el emparejamiento de un vector consigo mismo.

- **Entropía Espectral:** se calcula mediante la aplicación de la entropía de Shannon a la Densidad Espectral de Potencia (PSD, *Power Spectral Density*) normalizada,  $PSD_n(f)$ , de una señal  $x[n]$ . Este parámetro cuantifica la complejidad espectral de la señal y por esto se puede considerar como un estimador de irregularidad [41]. La entropía espectral se calcula de la siguiente manera:

$$SpecEn = -\frac{1}{\log(M)} \sum_{f=f_{min}}^{f_{max}} PSD_n(f) \log[PSD_n(f)], \quad (2.37)$$

donde  $M$  es el número de contenedores de frecuencia. La división por  $\log(M)$  normaliza la métrica a una escala de 0 a 1.

La densidad espectral de potencia se normaliza de la siguiente manera:

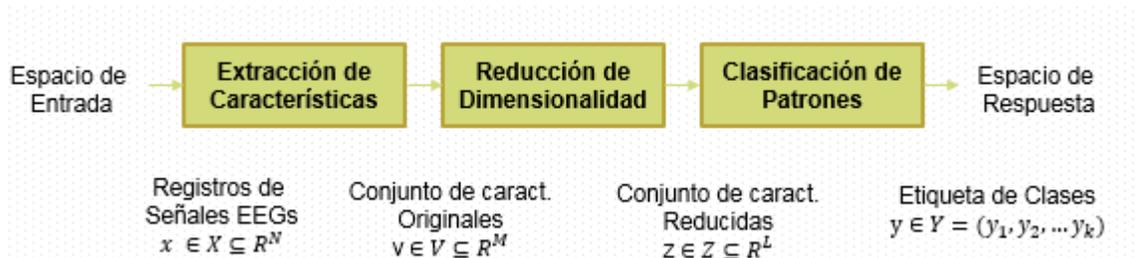
$$PSD_n(f) = \frac{PSD(f)}{\sum_{f=f_{min}}^{f_{max}} PSD(f)}. \quad (2.38)$$



## 2.2. REDUCCIÓN DE DIMENSIONALIDAD

Para realizar la clasificación es conveniente solucionar antes el problema que se presenta debido a la dimensión del vector de características. El número de características que se tienen en una señal puede ser demasiado grande, esto conlleva a que se presente redundancia cuando se trabaja con características que tienen alta correlación, por otro lado se tendrán datos con información poco significativa; es por esto que se presenta la necesidad de reducir la dimensionalidad de los datos de entrada. La reducción de dimensionalidad, además de solucionar los problemas anteriores, ayuda a optimizar el tiempo de cálculo, disminuir la complejidad del proceso de clasificación e incrementar el desempeño del clasificador.

Una representación del proceso de clasificación se ilustra en la figura 2.6, donde se tienen los datos de cada etapa de procesamiento,  $x \in X \subseteq R^N$  representa el espacio de entrada y  $y \in Y \subseteq \{y_1 \dots y_k\}$  la respuesta al espacio.



**Figura 2.6.** Etapas para extracción de características y clasificación de una señal. Adaptada de [26].

El conjunto de características  $v \in V \subseteq R^M$ , se obtiene de la etapa de extracción de características; cuando este conjunto es demasiado grande, lo más conveniente es utilizar una técnica de reducción de dimensionalidad, con la que se genera un nuevo conjunto de características  $z \in Z \subseteq R^L$ , con  $L < M$  [26].



Las técnicas de reducción de dimensionalidad se clasifican en dos clases: por **selección de características** y **proyección de características**. La primera busca minimizar el tamaño del conjunto original de características a través de la elección del mejor subconjunto o combinación de éstas; el criterio más utilizado para este caso es el Índice de Separabilidad de Clases (CSI, *Class Separability Index*). La segunda busca la mejor combinación de características a través de una transformación del conjunto original; para esta técnica, el método más conocido es el Análisis de Componentes Principales (PCA, *Principal Component Analysis*). Para el presente trabajo, se aplica la técnica de selección de características.

### 2.2.1. Selección de características

En este método se debe seleccionar el mejor subconjunto de características a partir del conjunto de la señal original, mediante la reducción del número de variables de éste.

El criterio más utilizado en reducción de dimensionalidad por selección de características es el Índice de Separabilidad de Clases (CSI). Este método ha demostrado ser eficaz en muchas aplicaciones biomédicas, además se considera sencillo y de baja complejidad computacional. Por lo tanto, será el implementado en el presente trabajo de grado [43] [44].

- **Índice de separabilidad de Clases CSI**

Los procedimientos estadísticos para estimar la separabilidad entre clases consisten en cuantificar que tan probable es la discriminación entre diferentes categorías, empleando para ello una medida de distancia estadística entre dos clases, como lo es el CSI. Éste es un criterio que permite evaluar el grado de separación de clases a partir de un vector de características dado, también se conoce como índice de Davies-Bouldin, y está representado por [45]:



$$CSI = \frac{1}{K} \sum_{i=1}^K \max_{i \neq j} (R_{ij}) = \frac{1}{K} \sum_{i=1}^k \max_{i \neq j} \left( \frac{S_i + S_j}{D_{ij}} \right), \quad (2.39)$$

donde:

- $R_{ij}$ : índice de similitud entre clases  $i, j$ .
- $S_i, S_j$ : grado de dispersión de las clases  $i, j$ .
- $D_{ij}$ : distancia media entre clases
- $K$ : es el número total de clases

Los parámetros de dispersión y distancia, pueden ser calculados de la siguiente forma:

$$S_i = \left[ \left( \frac{1}{N_i} \right) \sum_{j=1}^{N_i} (x_j - m_i)^T (x_j - m_i) \right]^{\frac{1}{2}}, \quad (2.40)$$

$$D_{ij} = \left[ (m_i - m_j)^T (m_i - m_j) \right]^{\frac{1}{2}}, \quad (2.41)$$

donde:

- $N_i$ : corresponde al número de muestras de la clase  $i$ .
- $x_j$ : corresponde a la  $j$ -ésima muestra de entrada en la clase  $i$ .
- $m_i$ : es la media de las muestras de la clase  $i$ .



De la ecuación (2.39), se puede deducir que entre más pequeño sea el valor del CSI, mayor será la separabilidad que existe entre las clases, lo cual significa que la caracterización que se logra es mejor.

## 2.3. CLASIFICACIÓN DE PATRONES

El desempeño de la etapa de clasificación de patrones dependerá en gran parte de que se haya realizado una buena extracción de características. En el paso de extracción de características y reducción de dimensionalidad se obtiene un patrón (conjunto de características), el cual corresponde a la entrada del clasificador, y la salida que se obtiene de éste es donde se identifica a qué clase corresponde el patrón o vector.

La función del clasificador es la de asignar una clase al patrón de entrada, para lograr esto se deben definir regiones de decisión, con lo que se busca que no exista superposición de las clases y que éstas se agrupen en una misma zona.

### 2.3.1. Formas de clasificación

Los algoritmos pueden ser clasificados de diversas formas, esto dependiendo de sus características. Se pueden identificar algoritmos *supervisados* y *no supervisados*, si se tiene en cuenta su proceso de aprendizaje; *lineal* y *no lineal*, de acuerdo a las operaciones que realicen; *paramétricos* y *no paramétricos*, en función de si se hacen suposiciones iniciales sobre el proceso a modelar [46].

- **Supervisada (aprendizaje):** en este tipo de clasificación se busca establecer un proceso de entrenamiento, esto con el fin de encontrar nuevas observaciones en las clases existentes.



- **No supervisada (sin aprendizaje):** en esta clasificación no hay un conocimiento previo de las clases que se tienen, tampoco existe un conjunto de observaciones, es por esto que no es posible realizar un diseño de funciones discriminantes. Las clases se forman a través de la agrupación de las muestras más próximas.
- **Método lineal:** un clasificador es lineal cuando se puede representar su umbral de decisión por una función lineal, como se aprecia en la figura 2.7.

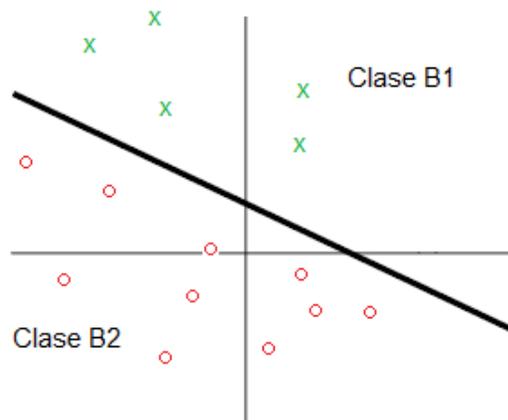


Figura 2.7. Problema separable linealmente. Adaptada de [46].

- **Método no lineal:** este tipo de clasificadores representan su umbral de decisión por una función arbitraria, como se observa en la figura 2.8.

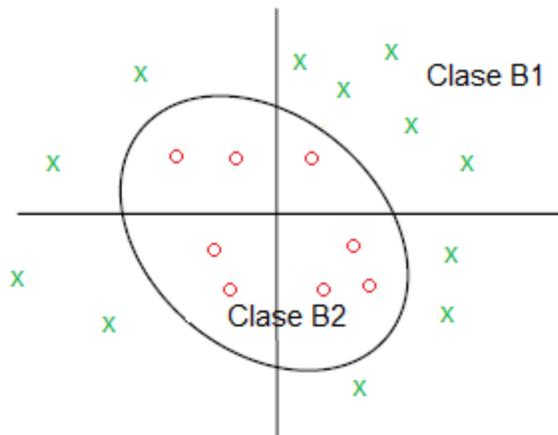


Figura 2.8. Problema no separable linealmente. Adaptada de [46].



- **Métodos de aprendizaje paramétricos:** este método realiza una búsqueda estadística, y supone que mediante la Función de Densidad de Probabilidad (PDF, *Probability Density Function*) se puede realizar la descripción total de los datos de entrada. El aprendizaje paramétrico, busca una relación matemática entre el sistema de entrada y salida, es decir, entre las señales de los sensores y las clases.
- **Métodos no paramétricos:** estos no utilizan la función de densidad de probabilidad para los datos de entrada, entre estos se tiene las Redes Neuronales Artificiales<sup>20</sup> (ANNs, *Artificial Neural Networks*) y sistemas expertos<sup>21</sup>.

### 2.3.2. Fundamentos teóricos de los clasificadores

En el momento de elegir un clasificador se debe tener en cuenta la dimensión del problema a tratar, es decir considerar las características y el tipo de información que se emplean como datos de entrada al sistema, como también las características que se pretenden obtener a la salida del mismo. Es importante elegir un clasificador con un bajo nivel de complejidad, que funcione de manera eficiente y que a partir de datos que no se presentan en el entrenamiento, realice buenas predicciones (generalización).

Los clasificadores que se van a implementar en el desarrollo del presente trabajo de grado para señales EEG, y que se han empleado en los artículos referenciados en [40] [47] y [48] son: Máquina de Soporte Vectorial (SVM, *Support Vector Machines*), Red Neuronal Probabilística (PNN, *Probabilistic Neuronal Network*) y Perceptrón Multicapas (MLP, *Multi Layer Perceptron*). Estos clasificadores serán explicados a continuación:

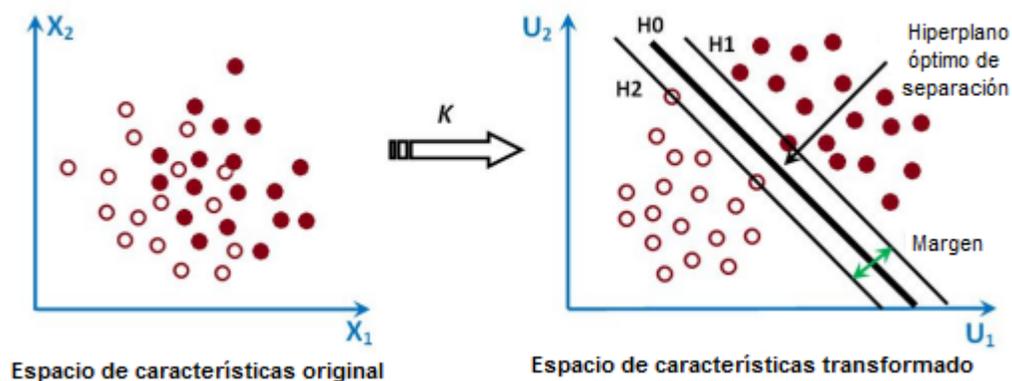
---

<sup>20</sup> Redes Neuronales Artificiales: son un paradigma de aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso biológico. Se trata de un sistema de interconexión de neuronas que colaboran entre sí para producir un estímulo de salida.

<sup>21</sup> Sistemas externos: son sistemas de computación, basados en conocimientos cuyos componentes representan un enfoque cualitativo de la programación.

- **Clasificador SVM:** este clasificador fue desarrollado por Vladimir Vapnik, se caracteriza por emplear técnicas de clasificación supervisada y no paramétrica (no necesita de hipótesis acerca de la densidad de probabilidad de los datos). La capacidad de generalización es una de las mayores ventajas de este clasificador, ya que busca determinar un hiperplano óptimo, con el que se obtenga una máxima distancia de separación entre los vectores transformados [6].

La distancia de separación se logra mediante dos planos paralelos que abarcan los puntos más cercanos al hiperplano óptimo, conocidos como vectores de soporte. Cabe resaltar que la capacidad de generalización es directamente proporcional a la distancia de separación, por lo que resulta conveniente una distancia grande como se puede apreciar en la figura 2.9 [6].



**Figura 2.9.** Funcionamiento de una SVM. Tomada de [6].

A continuación, se presentan las etapas que aplica una red SVM para realizar una clasificación de patrones [6]:

- Transformación del espacio de entrada o atributos en un espacio de trabajo de dimensión mayor, esto se consigue mediante el uso de las denominadas funciones Kernel.
- Cálculo del hiperplano óptimo que maximiza la distancia entre las clases consideradas.

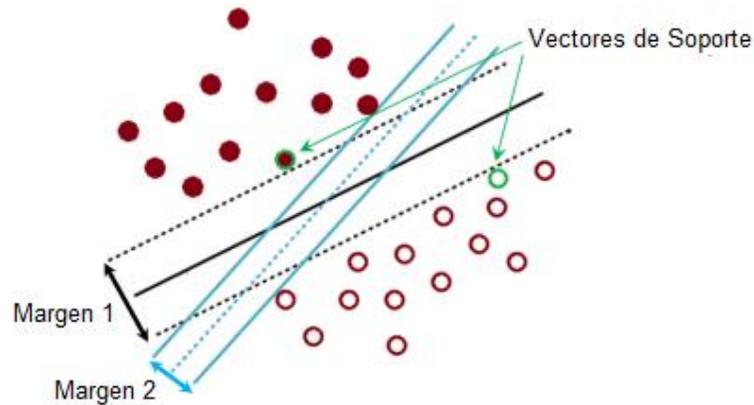


Existen distintos tipos de SVM, tales como: SVM lineal con margen máximo, SVM con margen blando y SVM para la clasificación no lineal. Su aplicación depende exclusivamente de los datos que se estén empleando en el proceso de clasificación [6].

1. SVM lineal con margen máximo: este tipo de SVM sólo es aplicable a datos linealmente separables en el espacio de características, es por esto que no es posible emplearla en la mayoría de casos reales de clasificación [6].

Los clasificadores SVM dividen los datos de entrenamiento en dos grupos que cuentan con una etiqueta propia, esto se realiza por medio de los hiperplanos que conforman. Las SVM poseen sólo un hiperplano óptimo de separación (HOS), éste se encuentra en medio de todos los posibles planos de separación de las dos clases etiquetadas. HOS interviene entre las clases como una línea de separación, es así como maximiza la distancia a los ejemplares más cercanos de éstas, llamándose a estos datos, *vectores de soporte*, sobre los que se establecerán dos hiperplanos H1 y H2, paralelos al hiperplano H0 [6].

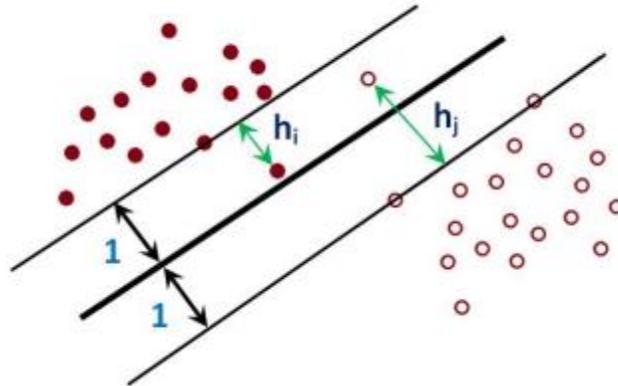
Los vectores de soporte corresponden a los puntos sobre los que se sobrepone el margen máximo. El HOS se elige de acuerdo a este margen. En la figura 2.10 se puede observar que el HOS es el de margen 1, ya que la separación entre H1 y H2 es mayor para éste, que para el de margen 2.



**Figura 2.10.** SVM linealmente separable. Selección del hiperplano de separación óptimo. Tomado de [6].

2. SVM con margen blando: el clasificador SVM con margen blando fue creado para solucionar el problema que se deriva del de margen máximo, ya que éste no tiene en cuenta la posibilidad de que existan vectores en la región abarcada por los hiperplanos  $H_1$  y  $H_2$ , y que estos puedan ser erróneamente clasificados. Por lo anterior, se concluye que la SVM de margen máximo no es la más óptima a la hora de trabajar con aplicaciones reales [6].

El objetivo de la clasificación de margen blando, es encontrar un HOS que logre separar los datos de tal manera que se obtenga el menor número de errores y un margen máximo entre los datos clasificados acertadamente, tal como se muestra en la figura 2.11. Este cambio en la forma de elegir el HOS incluye un nuevo grupo de variables que permiten ponderar el grado de desclasificación de cada vector, éstas se conocen como *variables de holgura*:  $h_i, i = 1, \dots, N$ , [6].

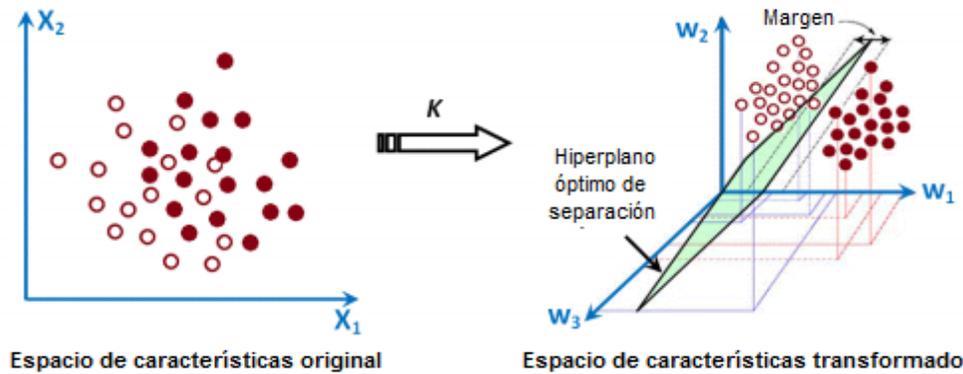


**Figura 2.11.** SVM linealmente separable. Margen blando. Tomado de [6].

3. SVM para la clasificación no lineal: los anteriores métodos lineales de clasificación no son los más óptimos en el momento de trabajar con aplicaciones reales; es por ello, que se creó un nuevo tipo de SVM basada en una función de transformación no lineal. Esta función busca transformar el conjunto de datos originales a otro de dimensión mayor, en donde las características transformadas sean separables linealmente. De esta manera a través del conjunto de datos transformado, se utilizaría el algoritmo de determinación de HOS como técnica de separación de dichos conjuntos [6].

Cabe resaltar que, pese a que el clasificador se basa en un hiperplano sobre el espacio de características transformado, éste podría ser no lineal en el espacio de características original.

El proceso para transformar los datos de un espacio inicial a uno de mayor dimensión se realiza a través de las denominadas funciones núcleo o kernel. Una función kernel  $k(x, y)$  es un producto interno en el espacio de características, que tiene su equivalente en el espacio de entrada. A continuación, se ilustra la forma en que la función kernel permite hacer la separación y el traslado de los datos al espacio de características [6].



**Figura 2.12.** SVM no linealmente separable. Transformación de los datos de entrada a un espacio de mayor dimensión inducida por una función kernel. Tomada de [6].

Existen multitud de funciones kernel, entre las más comunes se tiene: la función lineal, la función polinomial y la Función de Base Radial (RBF, *Radial Basis Function*)

- Lineal:

$$k(x, y) = xy. \quad (2.42)$$

- Polinómica:

$$k(x, y) = (\gamma xy + c)^\alpha, \quad (2.43)$$

donde  $c$  es un coeficiente,  $\alpha$  el rango del polinomio y  $\gamma$  es una constante de proporcionalidad .

- RBF

$$k(x, y) = \exp(-\gamma|x - y|^2). \quad (2.44)$$

Multclasificación con SVM: con el análisis realizado anteriormente se abarca el problema de clasificación para dos clases (con valores  $\pm 1$ ); sin embargo, hay que tener en cuenta que se presentan problemas con más de dos clases,



para dar solución a esto, se tienen dos tipos de arquitectura: las *multiclasificadoras* y las *biclasificadoras generalizadas*. Las máquinas multiclasificadoras construyen una función clasificadora global, teniendo en cuenta todas las posibles clases, para ello se varía la función objetivo de la SVM, en estas máquinas la complejidad algorítmica se presenta como su principal inconveniente. En cuanto a la máquina biclasificadora se tiene que, mediante un conjunto de funciones biclasificadoras, construye una función biclasificadora global. En esta máquina la simplicidad y el tiempo de respuesta son una ventaja frente a las multiclasificadoras; otro aspecto a resaltar es que este tipo de máquinas realizan la descomposición mediante dos técnicas: la técnica *uno contra uno* y la *técnica uno contra todos*, la primera es muy costosa y poco efectiva, ya que por cada par de clases diferentes se construye un clasificador binario, mientras que la segunda técnica lo hace para cada clase, intentando escoger entre una y las demás, eligiendo la clase en la cual la SVM alcanza la mayor salida [49].

- **Clasificador PNN:** esta red fue desarrollada por Specht, se caracteriza por su simplicidad, generalidad y rapidez, por lo cual se utiliza en reconocimiento de patrones y problemas de clasificación. Este modelo se puede considerar de tipo híbrido por integrar aprendizaje supervisado y no supervisado. La velocidad de entrenamiento de este clasificador es rápida, esto se debe a que el proceso de ajuste de los pesos no se repite y el aprendizaje es directo [50] [51].

La PNN es una familia de las Redes de Funciones de Base Radial<sup>22</sup> (RBFN, *Radial Function Network*). Estas funciones se utilizan centradas sobre cada patrón de entrenamiento para realizar la estimación de las Funciones de Densidad de Probabilidad de cada clase [51].

Como se observa en la figura 2.13, una red PNN está formada por cuatro capas, a saber: capa de entrada, capa de neuronas de base radial o capa de

---

<sup>22</sup> Redes de Funciones de Base Radial: es un tipo de red neuronal, estas usan funciones de base radial cuyo valor real depende de la distancia al origen.



patrones, capa competitiva o de sumalización y capa de salida, las cuales se explican brevemente a continuación [51]:

- Capa de entrada: en esta capa la cantidad de nodos, es equivalente al número de características que tenga el vector o patrón de entrada.
- Capa de base radial o capa de patrones: la cantidad de neuronas es proporcional al número de patrones de entrenamiento. Cada neurona calcula la gaussiana de la distancia Euclídea, entre el vector de entrada y el vector objetivo, generando un vector que muestra la proximidad entre estos. De esta manera, las neuronas evalúan su salida a través de un kernel gaussiano de la forma [52]:

$$F_{k,i}(\mathbf{X}) = \frac{1}{(2\pi\sigma^2)^{\frac{n}{2}}} \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_{k,i}\|^2}{2\sigma^2}\right), \quad (2.45)$$

donde  $\mathbf{x}_{k,i}$  es el centro del kernel y  $\sigma$  un parámetro de dispersión (spread), éste define el tamaño del campo receptivo o esfera de influencia del respectivo kernel.

- Capa competitiva o de sumalización: en este caso el número de neuronas corresponde al número de clases. Cada neurona suma las salidas de la capa anterior para cada clase de entrada y genera con ellas un vector de salida con las probabilidades. En la salida una función de transferencia de tipo competitivo elige la mayor de estas probabilidades, produciendo un 1 para esa clase y 0 para las otras.
- Capa de salida: formada por nodos que son neuronas binarias encargadas de producir la decisión de clasificación. Esta capa entrega la etiqueta de clasificación.

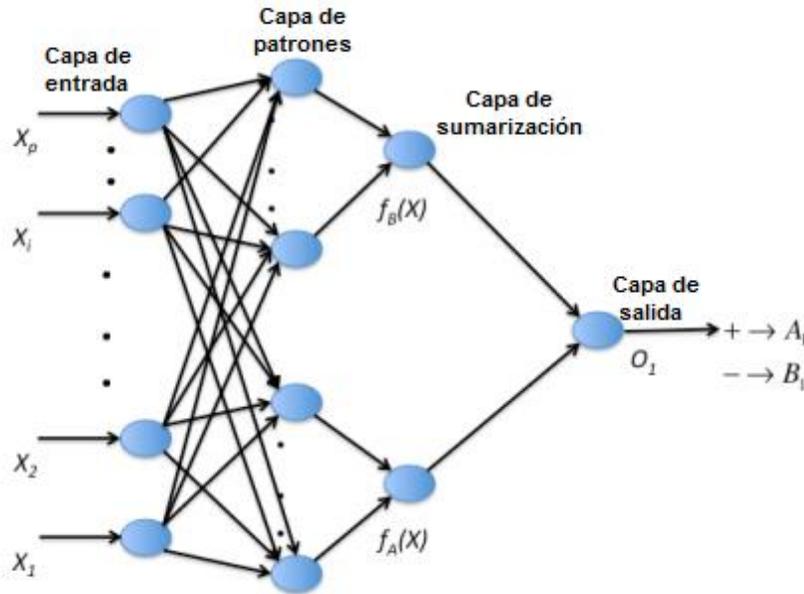
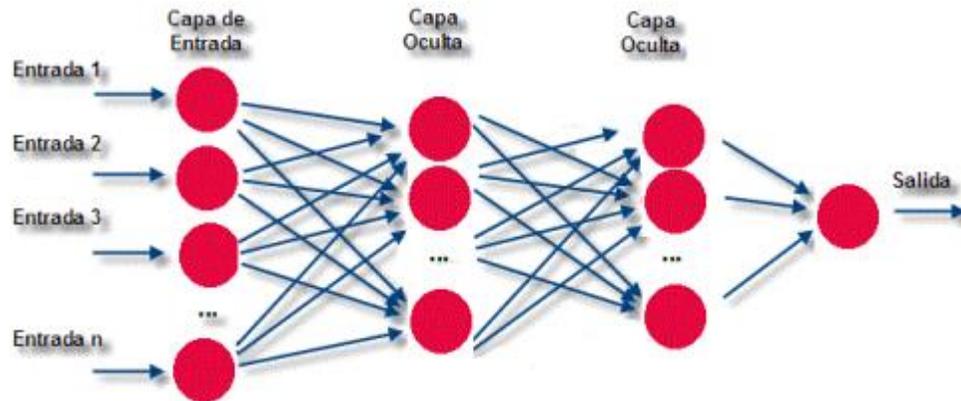


Figura 2.13. Arquitectura de una red PNN. Adaptada de [51].

- **Clasificador MLP:** este clasificador es un tipo de Red Neuronal Artificial, que imita la capacidad de aprendizaje del sistema nervioso. MLP es no lineal y de aprendizaje supervisado; normalmente es utilizado en problemas de clasificación de patrones. Se caracteriza por solucionar problemas para los casos en que las clases no son linealmente separables, esto se debe a que está constituido por diversas capas, las cuales poseen neuronas artificiales (perceptrones),<sup>23</sup> encargadas de ejecutar diferentes transformaciones sucesivas [6] [53].

En la figura 2.14 se ilustra la arquitectura MLP, en este caso la más común compuesta por tres capas activas, dos capas ocultas y una de salida.

<sup>23</sup> Perceptrón: modelo de sistema capaz de aprender mediante entrenamiento supervisado, contiene un conjunto de pesos ajustables y una función de activación tipo escalón.



**Figura 2.14.** Estructura de un MLP con una capa de entrada y tres capas activas. Tomada de [6].

- **Capa de entrada:** las neuronas que pertenecen a esta capa reciben los datos de entrada, pero no realizan ningún cálculo sobre estos, su función es la de transmitirlos a la siguiente capa.
- **Capa oculta:** las neuronas localizadas en esta capa son elementales para el aprendizaje de los patrones, y para determinar la relación entre la entrada y la salida. Generalmente se utiliza una sola capa oculta para establecer esta relación, sin embargo se pueden emplear más.
- **Capa de salida:** se encuentran las neuronas que representan las clases que pueden predecirse.

El procesamiento de la información en la capa oculta y de salida se realiza de la siguiente manera: primero, las variables de entrada  $x_i$  se combinan con los pesos  $w_i$  de cada conexión, generando una suma ponderada; posteriormente, se debe convertir la suma ponderada en una variable de salida, esto se realiza por medio de una función de transformación. La variable de salida se define a través de la ecuación (2.46) [53].

$$Salida_n = f\left(\sum_i w_i x_i\right). \quad (2.46)$$



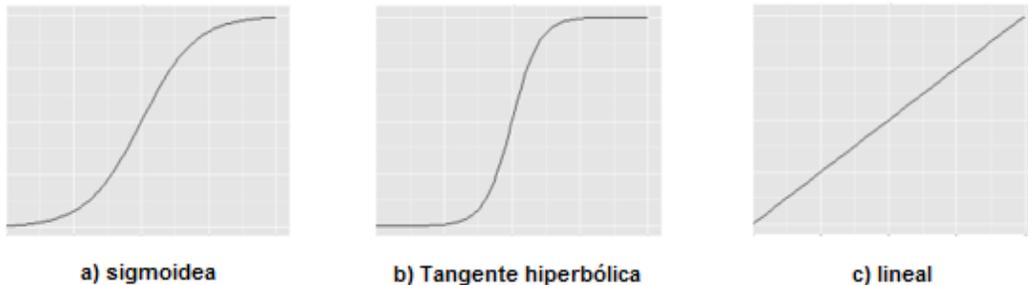
Se tienen diferentes funciones de activación o transformación  $f(x)$ , entre las más empleadas se tiene: la función Sigmoide, Tangente Hiperbólica y Lineal, las cuales se representan mediante las ecuaciones (2.47), (2.48) y (2.49) respectivamente

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (2.47)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (2.48)$$

$$f(x) = x. \quad (2.49)$$

En la figura 2.15 se ilustra las funciones de activación más comunes:



a) sigmoidea

b) Tangente hiperbólica

c) lineal

**Figura 2.15.** Funciones de activación comunes. Adaptada de [54]

Los pasos del entrenamiento de una red MLP son [54]:

- La red neuronal se carga con ejemplos entrenados, conformados por los patrones de entrada y los patrones de salida deseados.
- Se calcula la suma ponderada mediante la determinación del peso de cada variable de entrada.
- La función de transformación es aplicada a la suma ponderada.



- Se realiza una comparación entre los datos obtenidos y los patrones de salida deseados, posteriormente se verifica que tan cerca están dichos valores.
- Por último se tiene que los pesos pueden ser cambiados, para obtener una mayor aproximación a los valores de salida deseados.

Los pasos anteriores se pueden realizar las veces que se necesite, hasta conseguir una diferencia mínima entre los valores de salida obtenidos y los deseados.

En este capítulo, se realizó el estudio de técnicas de reconocimiento de patrones y la DWT, aplicadas al análisis de señales bioeléctricas (EEG).

En el capítulo 3 se explicará el diseño e implementación del algoritmo para extracción de características de señales EEG aplicando DWT, esto con la finalidad de identificar los tres estados que se analizan en el presente trabajo.



## CAPÍTULO 3

# DISEÑO E IMPLEMENTACIÓN DEL ALGORITMO DE EXTRACCIÓN DE CARACTERÍSTICAS.

### 3.1. FASE DE ANÁLISIS

La caracterización que se realiza de las señales EEG tiene como fin poder discriminar tres estados (normal, ictal, postictal), que se presentan en una señal electroencefalográfica, cuando una persona sufre epilepsia, los cuales se pueden apreciar en la figura 3.1.

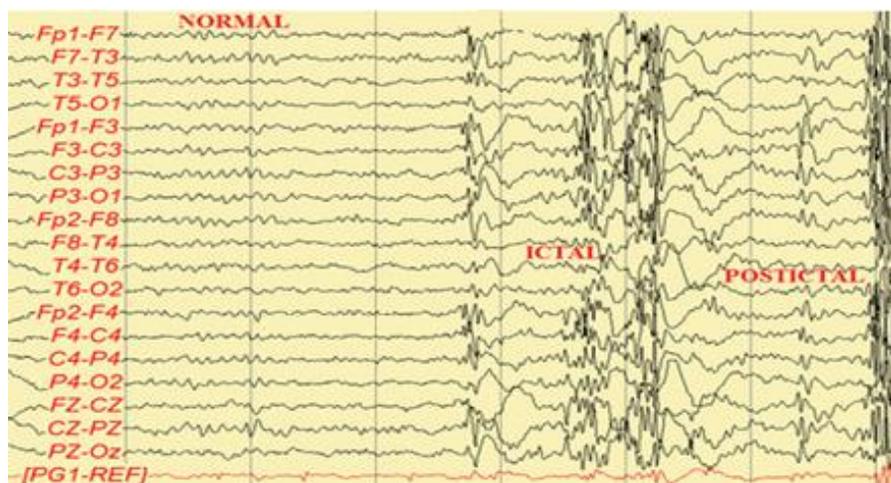


Figura 3.1. Estados que se presentan en una señal EEG. Tomada de [55]



La eficiencia del algoritmo de extracción de características requiere, que el vector descriptor construido para cada estado, contenga la información más importante y la menor dimensión posible, esto se logra eliminando la información redundante. Así mismo, entre el conjunto de características que forman el vector descriptor debe haber una adecuada separación, para lograr una buena precisión en la clasificación de patrones y requerir una carga computacional baja, con lo cual se busca reducir los retardos en la selección de estados. La eficiencia del conjunto de características extraídas se evalúa mediante los índices CSI y el error de clasificación.

### 3.2. FASE DE DISEÑO

El software de simulación Matlab R2015a, es la herramienta utilizada para realizar las respectivas pruebas del sistema de reconocimiento de patrones en señales EEGs, tanto en la fase de extracción de características, como en la reducción de dimensionalidad y la clasificación de señales EEGs.

Se seleccionó el software de simulación Matlab, debido a:

- Reconocimiento a nivel internacional, frente a la comunidad investigativa y científica.
- La Universidad del Cauca cuenta con este software licenciado, lo que facilita su utilización.
- Matlab es un lenguaje de alto nivel similar a C, el cual permite asociar sentencias que se emplean frecuentemente dentro de un programa que puede ser invocado después, con lo que se logra un mejor manejo de las funciones.

Matlab cuenta con librerías especializadas (*toolboxes*), para el desarrollo de este proyecto se empleó el *toolboxes wavelet* versión 4.14.1.



### 3.2.1. Wavelet Toolboxes

Wavelet toolboxes es una librería que cuenta con funciones y aplicaciones que permiten realizar el análisis y síntesis de señales, imágenes y datos, las cuales se caracterizan por un comportamiento regular con cambios abruptos, igualmente cuenta con algoritmos para la CWT, DWT y WPT. Además, permite analizar cómo el contenido de frecuencia de una señal cambia en el tiempo, y muestra patrones comunes en múltiples señales. Así mismo, permite realizar análisis multiresolución, ya sea para extraer características a escala-fina o a gran-escala, reconocer discontinuidades y encontrar puntos de cambio o sucesos que no son evidentes en los datos brutos. Otra aplicación de Wavelet toolboxes es la compresión de datos y la eliminación de ruido en señales e imágenes [56].

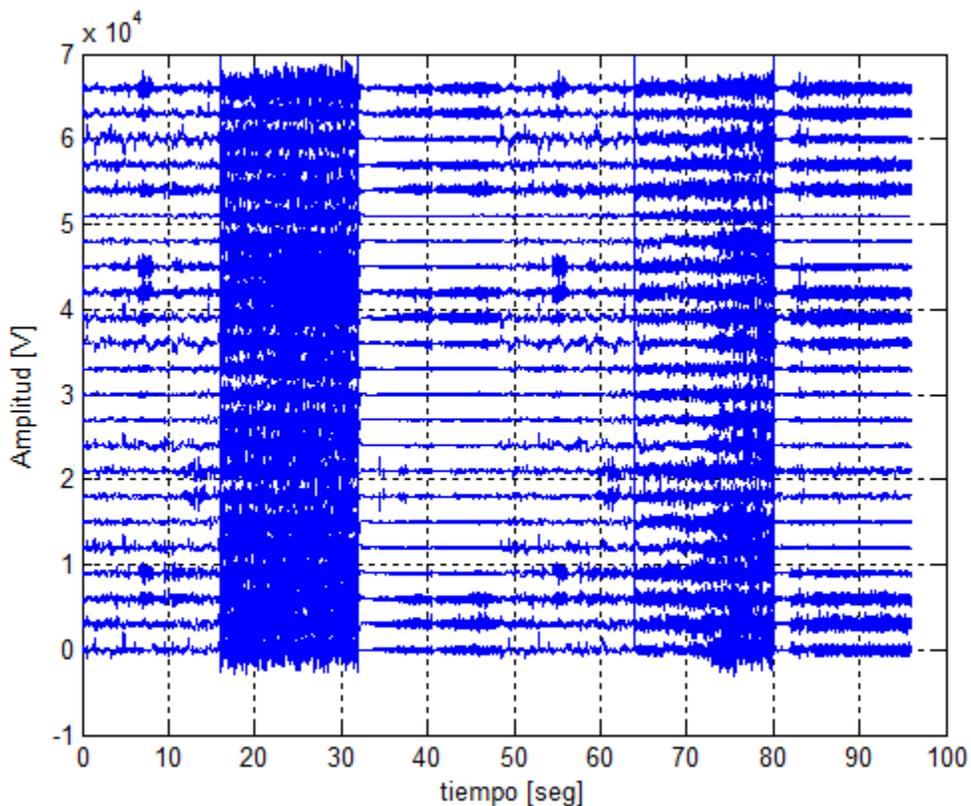
### 3.2.2. Selección de la base de datos de señales EEG

La base de datos CHB-MIT descrita en el capítulo 2, fue modificada para fines del proyecto de grado. Inicialmente las grabaciones fueron recortadas a un total de 96 segundos, eligiendo la información útil para el proyecto y evitando la carga computacional, en el momento de trabajar con la herramienta de Matlab. Posteriormente, de los 22 pacientes del conjunto de datos se seleccionaron 5, en los cuales se pudo observar con mayor claridad los cambios abruptos en la señal, correspondientes a las crisis epilépticas; lo anterior, se puede afirmar gracias a que en la base de datos se encuentra información concerniente al tiempo de inicio y fin de las crisis.

Cabe resaltar que para el proyecto se cuenta con una base de datos para entrenamiento y otra base de datos para pruebas, cada una con 5 pacientes diferentes. La primera se utiliza para entrenar el clasificador, y la segunda para probarlo. De cada paciente se tiene un registro guardado en forma matricial de 256x96x23; el número 256 corresponde a la frecuencia de muestreo de la



señal, 96 es el resultado de los 16 segundos de grabación para cada uno de los 3 estados en 2 sesiones<sup>24</sup> y por último se tiene el número 23 de la dimensión de la matriz, que corresponde a la cantidad de canales (o electrodos), utilizados para cada paciente. En la figura 3.2, se puede visualizar los 96 segundos de grabación para tres estados, en 23 electrodos. En el anexo A se presenta la respectiva información de los canales, los cuales están conformados por pares de electrodos, siguiendo la configuración del sistema internacional 10-20. También se ilustra información acerca de la edad y sexo de los pacientes de la base de datos.



**Figura 3.2.** EEG correspondiente al paciente 5 de entreno.

En el presente trabajo de grado se buscó la detección de los tres estados: normal, ictal y postictal para su respectiva clasificación, por lo cual se realizó

<sup>24</sup> Una sesión corresponde a la grabación que contiene los estados normal, ictal y postictal con 16 segundos cada uno.



un trabajo de selección de los dos mejores canales, con los que se obtuvieran buenos resultados en el proceso de discriminación y clasificación.

Para construir los vectores descriptores de las señales EEG, es importante tener en cuenta la dimensión de estos, ya que pueden influir sobre el error de clasificación. En estudios realizados sobre clasificación de patrones EEGs, se recomienda que la cantidad de muestras de entrenamiento sea mayor que el tamaño del vector descriptor [57], [58].

### **3.2.3. Selección de canales y características mediante CSI**

Se empleó el CSI como mecanismo de reducción de dimensionalidad y para la selección de los mejores canales por paciente. Este procedimiento se realizó, ya que se buscaba que el conjunto de características presentara una buena separabilidad entre clases (distancia estadística maximizada). En este trabajo se seleccionaron las características que ofrecieron los mejores niveles de CSI.

En la figura 3.3.a se observa como las clases se superponen, esto se presenta cuando el CSI es alto, lo cual hace difícil la tarea de clasificación, por el contrario en la figura 3.3.b se puede apreciar buena separabilidad entre clases, que se logra con un CSI bajo, facilitando de esta manera la clasificación. La separabilidad entre clases, puede obtenerse seleccionando los mejores canales y características que ofrezcan mayor discriminación.

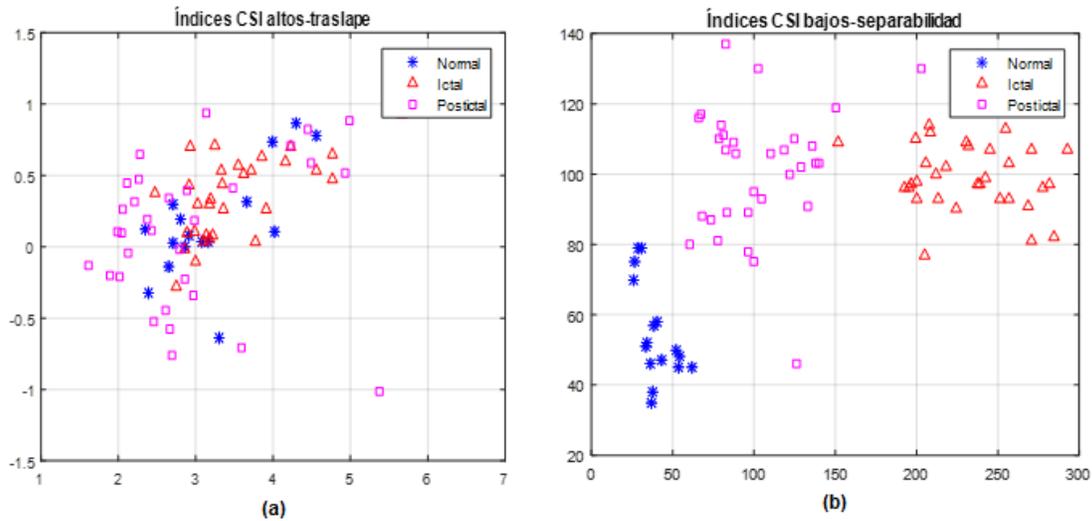


Figura 3.3. Traslape o separabilidad de clases según el índice CSI.

La extracción de características se realizó sobre todos los canales que se utilizaron en la obtención de las señales EEG, ya que se supone que todos pueden contener información importante en el momento de realizar la discriminación de estados, aunque algunos brindan más información que otros. A continuación se explica el procedimiento que se siguió para elegir los mejores canales y características empleados en la clasificación de las señales EEGs.

- **Selección de canales:** se procedió a aplicar el CSI sobre todas las características implementadas para discriminar los tres estados, esto se realizó en todos los canales, para cada paciente. Con este procedimiento se eligió los dos canales que presentaron el menor valor de CSI.
- **Extracción y selección de características:** una vez seleccionados los dos canales para cada paciente y característica, se procedió a descartar aquellas que no cumplieron con un valor de CSI bajo, que garantizará la separabilidad entre los estados a clasificar.



### 3.2.4. Características Temporales

El método de *evaluación de parámetros* es utilizado para la extracción de características temporales. En el capítulo 2 fueron descritos los parámetros: media, varianza, desviación estándar (DS), asimetría, curtosis, coeficiente de variación, Valor Medio Absoluto (VMA), Cruces por Cero (CC), Cambios de Signo de Pendiente (CSP) y Longitud de Onda (LO), los cuales se evaluaron sobre todos los canales.

#### ➤ Selección de canales

Con los parámetros anteriores, se procedió a encontrar los dos canales que ofrecieron el promedio CSI más bajo, en la tabla 3.1 se muestran los resultados. Los promedios CSI correspondientes a cada canal, se pueden observar en el apéndice I.



**Tabla 3.1.** Mejores canales según el CSI para los parámetros temporales. Por los autores

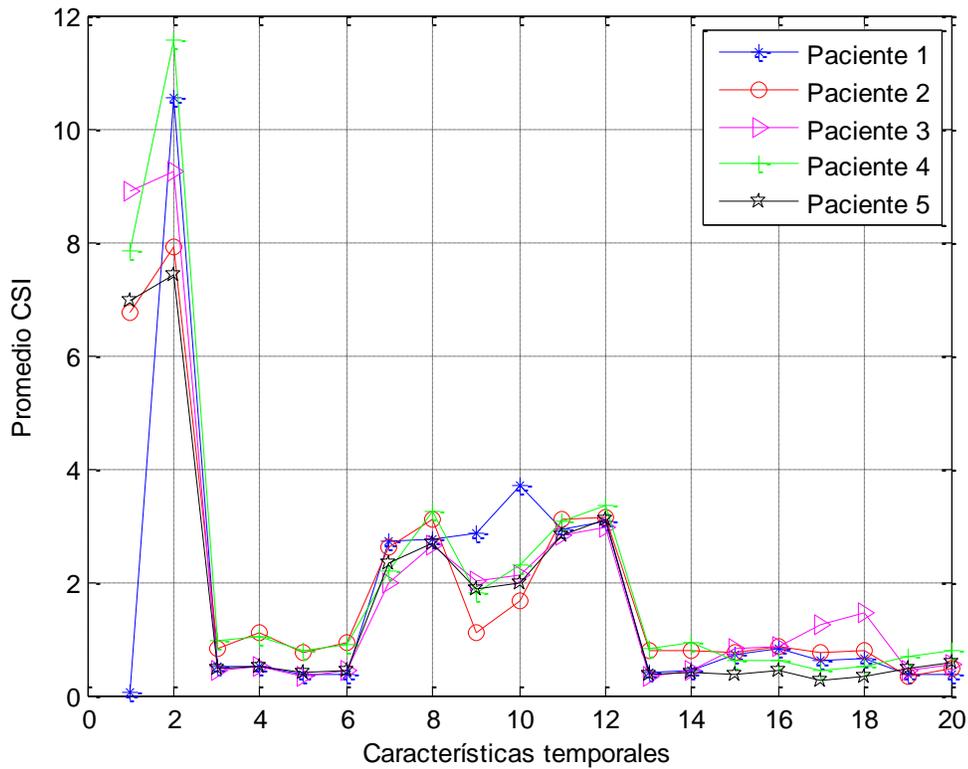
PACIENTE	MEJORES CANALES									
	Media	Varianza	Desviación estándar	Asimetría	Curtosis	Coefficiente de variación	VMA	CC	CSP	LO
1	23	10	2	12	3	9	10	15	10	1
	12	2	10	8	8	17	2	1	15	21
2	19	27	27	15	27	9	27	26	19	8
	16	8	8	16	19	12	8	21	24	9
3	3	3	3	1	21	9	3	19	11	21
	8	20	20	18	2	8	7	3	15	17
4	22	11	11	2	21	8	11	22	17	14
	27	7	7	16	19	17	7	17	19	26
5	16	4	4	5	12	20	5	1	18	6
	18	5	5	3	2	5	4	21	17	11

En la tabla 3.1 se tienen los dos mejores canales por paciente y por parámetro, organizados de menor a mayor CSI, donde se observa que estos no necesariamente coinciden para los pacientes, ni para los parámetros evaluados.



➤ **Extracción y selección de características**

En la figura 3.4, se presentan los promedios CSI para las características correspondientes a los parámetros temporales, cada uno evaluado sobre los dos mejores canales (ver tabla 3.1).



Intervalo	1,2	3,4	5,6	7,8	9,10	11,12	13,14	15,16	17,18	19,20
Parámetro	Media	Varianza	Desviación estándar	Asimetría	Curtosis	Coefficiente de Variación	VMA	CC	CSP	LO

**Figura 3.4.** Promedios CSI para los parámetros temporales evaluados en dos canales.

Se observa que los parámetros media, asimetría, curtosis y coeficiente de variación son los que presentan los promedios CSI más altos en todos los pacientes, por lo tanto se procede a eliminarlos. Por otra parte, se tiene el



parámetro CSP que presenta un valor alto para el paciente 3, pero es aceptable, por lo que se decide conservarlo.

Una vez realizado el análisis de los parámetros temporales a través del Índice de Separabilidad de Clases, se concluye que los parámetros con mayor capacidad discriminante son: varianza, desviación estándar, VMA, CC, CSP y LO.

### 3.2.5. Características Espectrales DWT

En esta etapa las características se obtienen mediante la Transformada Wavelet Discreta, la cual inicia con una descomposición DWT sobre los registros EEGs, que corresponden a una matriz de 256x16 representando un estado en una sesión, en este proceso se escoge la wavelet madre  $\psi(t)$  y el nivel de descomposición más apropiados. Además de esto, se puede elegir las subbandas en las cuales se presente mayor concentración de energía o contengan información discriminante para los registros EEGs, con lo anterior se logra hacer más eficiente la etapa de extracción de características.

#### ➤ Nivel de descomposición DWT.

En una secuencia temporal de longitud  $N=256$  correspondiente a los registros EEGs, se tiene un nivel máximo de descomposición  $J=8$  ( $J = \log_2 N$ ). De acuerdo a [59-61], las descomposiciones más comunes para las señales EEG se realizan para los niveles  $J=5$  y  $J=4$ .

El ancho de banda de las señales EEGs va de 0.5 a 100Hz, por lo que se tiene que al realizar una descomposición DWT a nivel 5, las secuencias de coeficientes de aproximaciones y detalles, quedan organizadas en las siguientes subbandas de frecuencias:



**Tabla 3.2.** División de frecuencias a una tasa de muestreo de la señal de 256 Hz a un nivel de descomposición 5. Por los autores.

Rango de frecuencias (Hz)	Nivel de descomposición	Tipo de onda
64-128	D1	Ruido
32-64	D2	Gamma
16-32	D3	Beta
8-16	D4	Alfa
4-8	D5	Theta
0-4	C5	Delta

Las señales EEG presentan su contenido de frecuencia útil hasta los 30 Hz [62], ya que los componentes de alta frecuencia corresponden a ruido o artefactos; en el caso del ruido de las líneas eléctricas, éste se encuentra en un rango de frecuencias de 50 Hz o 60 Hz. De lo anterior se puede deducir que para el análisis de las señales EEG bastaría realizar una descomposición a nivel 4.

➤ **Selección de la función wavelet.**

En la descomposición DWT es necesario escoger la función wavelet. Entre las familias de funciones wavelets, que proporcionan un espacio para buscar una onda que represente eficientemente la señal deseada, se encuentran: Biorthogonal, Coiflet, Haar, Symlet y Daubechies. Para elegir la wavelet más adecuada se tiene en cuenta su similitud con la señal a procesar, en este caso, se escoge Daubechies 4 (db4) debido a que se trabaja con señales EEG, y esta función ofrece un suavizado adecuado para la detección de cambios en estas señales [5], [59-61].



### ➤ Selección de subbandas DWT

Al realizar una descomposición DWT se obtiene una matriz con los coeficientes de detalle de todos los niveles  $D_j, D_{j-1}, \dots, D_1$  y la aproximación del último nivel  $C_j$ , de esta manera se tiene que para una descomposición de nivel 4, los coeficientes quedan distribuidos en las siguientes bandas de frecuencia:

**Tabla 3.3.** División de frecuencias a una tasa de muestreo de la señal de 256 Hz a un nivel de descomposición 4. Por los autores.

Rango de frecuencias (Hz)	Nivel de descomposición
64-128	D1
32-64	D2
16-32	D3
8-16	D4
0-8	C4

La selección de subbandas se considera como un método de reducción de dimensionalidad por selección de características. La eliminación de ciertas subbandas se realizó teniendo en cuenta un previo análisis de la información teórica acerca de las señales EEG, en donde las subbandas que se conservan son aquellas que contienen la información más útil, es decir, mayor concentración de energía. Según [63] durante una crisis epiléptica la energía de la señal de EEG se incrementa para casi todo su rango de frecuencias (0.5 a 100Hz). Este incremento se debe no solo a la crisis en sí, sino también a la reacción de la persona frente a dicha crisis. Normalmente la banda de frecuencias que se identifica con la actividad epiléptica es la que se encuentran entre algunas décimas de Hertz y alrededor de los 25 Hz; mientras que el incremento de la energía a frecuencias mayores a estas puede asociarse a la actividad muscular que se genera por dichas crisis.



De lo anterior se concluye que las subbandas que proporcionan mayor concentración de energía y que pueden identificar una crisis epiléptica son {C4, D4, D3}, por lo tanto serán las subbandas que se tendrán en cuenta para el presente trabajo de grado.

Con el nivel de descomposición wavelet DWT, la función wavelet y las subbandas seleccionados anteriormente, se inicia el proceso de extracción de características espectrales, empleando los coeficientes obtenidos a través de la descomposición DWT; para este proceso se emplea el método de *evaluación de parámetros*.

En el capítulo 2 fueron descritos los parámetros espectrales: Descomposición en Valores Singulares (SVD), Energía de escala (Ener), Promedio absoluto de coeficientes (AVG), el máximo en la escala (MAX), Varianza (VAR), Entropía Aproximada (ApEn), Entropía Muestral (SampEn) y Entropía Espectral (SpecEn), los cuales se evaluaron sobre todos los canales.

#### ➤ **Selección de canales**

De los parámetros anteriores, se procede a encontrar los dos canales que ofrezcan el promedio CSI más bajo, en la tabla 3.4 se muestran los resultados. Los promedios CSI correspondiente a cada canal se pueden observar en el apéndice II.



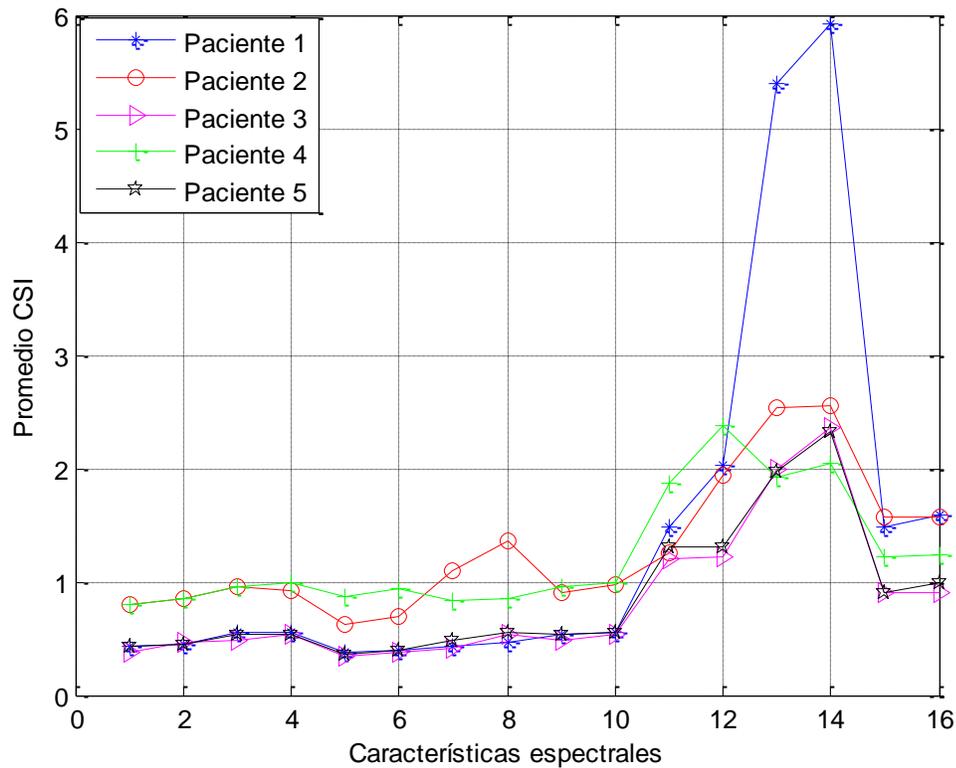
**Tabla 3.4.** Mejores canales según el CSI para los parámetros espectrales. Por los autores

PACIENTE	MEJORES CANALES							
	SVD	Ener	AVG	MAX	VAR	ApEn	SamPen	SpecEn
1	2	10	15	10	2	21	20	13
	10	2	1	2	10	5	14	7
2	27	8	8	27	27	25	22	27
	8	27	27	8	8	19	14	21
3	3	3	3	3	3	4	17	3
	20	20	20	20	20	3	15	19
4	7	7	11	7	7	4	9	17
	11	11	7	11	11	9	17	27
5	5	5	5	4	5	22	5	18
	9	9	9	17	9	6	13	8

En la tabla 3.4 se tienen los dos mejores canales por paciente y por parámetro, organizados de menor a mayor CSI, donde se observa que estos no necesariamente coinciden para los pacientes, ni para los parámetros evaluados

#### ➤ Extracción y selección de características

Los parámetros espectrales se evalúan en la *matriz de coeficientes wavelet*, constituida por las subbandas de información más útil {D3, D4, C4}. En la figura 3.5 se presentan los promedios CSI para las características correspondientes a estos parámetros, cada uno evaluado sobre los dos mejores canales (ver tabla 3.1).



Intervalo	1,2	3,4	5,6	7,8	9,10	11,12	13,14	15,16
Parámetro	SVD	Ener	AVG	MAX	VAR	ApEn	SamPen	SpecEn

**Figura 3.5.** Promedios CSI para los parámetros espectrales sobre la matriz de coeficientes DWT

Se observa que los parámetros ApEn, SampEn y SpecEn presentan los promedios CSI más altos en todos los pacientes, por lo tanto se decide eliminarlos. El siguiente parámetro con el promedio CSI más alto es MAX, para el paciente 2, pero este es un valor aceptable, por lo que se decide conservarlo.

Una vez aplicado el CSI para seleccionar los mejores parámetros espectrales, se concluye que estos son: SVD, Ener, AVG, MAX y VAR



### **3.2.6. Conformación de los vectores simples (DT y DWT) e híbridos (DT - DWT)**

La clasificación de las señales EEGs se realiza a partir de vectores simples o híbridos. Los vectores simples son formados por características extraídas de las señales EEG aplicando una sola técnica, éstas pueden ser DT o DWT y los vectores híbridos, se conforman a partir de la combinación de dos o más técnicas, por ejemplo DT-DWT. Hasta el momento se cuenta con vectores simples conformados de 12 características DT (6 parámetros x 2 canales) y 10 Características DWT (5 parámetros x 2 canales), es decir, se tiene un vector híbrido DT-DWT con un total de 22 características. Cabe resaltar que la conformación de estos vectores, se realizó con las características más discriminantes que se obtuvieron a través del CSI; sin embargo, será mediante la implementación de un clasificador que se definirán las características que conformarán definitivamente los vectores, esto se realizará evaluando el error de clasificación para cada paciente, los resultados se muestran en el capítulo siguiente.

## **3.3. FASE DE IMPLEMENTACIÓN**

En esta fase se describen las funciones más relevantes que se emplearon para extracción de características y reducción de dimensionalidad.

### **3.3.1. Extracción de Características en el dominio del tiempo**

- **Función `caract_tempo`**



Esta función recibe como parámetros de entrada la información de dos canales ch1 y ch2, es la encargada de formar los vectores de características temporales, los cuales entrega como un parámetro de salida.

*caracteristicas\_DT = caract\_tempo (ch1, ch2)*

'ch1' y 'ch2', son las variables que representan las secciones de 256 muestras de los registros EEG.

### 3.3.2. Extracción de Características en el dominio espectral

#### ➤ Función *caract\_DWT*

Esta función recibe como parámetros de entrada la información de dos canales ch1 y ch2, y es la encargada de formar los vectores en el dominio espectral empleando DWT.

*caracteristicas\_DWT = caract\_DWT (ch1, ch2)*

La función *caract\_DWT* entrega como salida un vector formado por las características DWT, que representan a cada estado.

### 3.3.3. Índice de Separabilidad de Clases

Como se mencionó en la fase de diseño, el CSI es una herramienta útil para medir la eficiencia del algoritmo de extracción de características, la función que permite su evaluación es la siguiente:



➤ **Función *calcula\_CSI.m***

La función *calcula\_CSI*, es la encargada de calcular los valores de CSI sobre los diferentes conjuntos de características extraídas.

*indices\_csi = calcula\_CSI (caracteristicas)*

La variable de entrada 'características', corresponde a un arreglo vectorial conformado por las características extraídas a través del método de evaluación de parámetros.



## CAPÍTULO 4

# CLASIFICACIÓN DE PATRONES EEGs

La fase final de procesado en las señales EEGs corresponde a la clasificación de patrones y detección de estados, es decir, una vez determinados los patrones o vectores de características, se procede a implementar un clasificador que tenga la capacidad de discriminar las señales y definir a que clase pertenecen. Para el desarrollo de esta fase se cuenta con dos bases de datos: una para entrenamiento y otra para prueba.

- Vectores de entrenamiento: los clasificadores se entrenan sobre la base de datos de entreno, esto lo realizan a partir de los vectores obtenidos en la fase de extracción de características de las señales EEGs.
- Vectores de prueba: una vez realizado el entrenamiento del clasificador se procede a validarlo, lo cual se realiza sobre una segunda base de datos de prueba.

Para conformar los vectores definitivos se realizó la evaluación del error de clasificación sobre 5 pacientes, mediante la combinación aleatoria de las características más discriminantes que se obtuvieron aplicando el CSI; es así, como se determinó qué combinación de características brindaba el menor error de clasificación y por ende una buena caracterización de estados. Este procedimiento se efectuó solamente con el clasificador SVM, ya que realizarlo



para la totalidad de los clasificadores implementados en el trabajo de grado resultaría dispendioso y poco práctico.

Al realizar el procedimiento anterior se obtuvo que los parámetros que brindan un menor error de clasificación son: Desviación estándar (DS), Longitud de la forma de Onda (LO), Descomposición en Valores Singulares (SVD), el promedio absoluto de coeficientes (AVG) y la varianza (VAR). Con lo que se obtiene vectores simples conformados de 4 características DT (2 parámetros x 2 canales) y 6 Características DWT (3 parámetros x 2 canales), es decir, se tiene un vector híbrido definitivo DT-DWT con un total de 10 características.

Con el fin de hacer más óptimo el proceso de clasificación se realizaron diferentes pruebas, evaluando mediante el algoritmo SVM los mejores canales encontrados según el CSI, para cada una de las características del vector híbrido DT-DWT (Tabla 3.1, 3.4), con lo que se encontró que el menor error de clasificación se encuentra para los canales de menor valor CSI evaluado en el parámetro LO, por lo que se decidió trabajar con estos.

A continuación, se ilustran los resultados del desempeño del vector de características en los diferentes clasificadores implementados.

## **4.1. ERROR DE CLASIFICACIÓN PARA LAS CARACTERÍSTICAS DT, DWT Y DT-DWT**

### **➤ Error de clasificación para 3 estados (normal, ictal y postictal)**

Los resultados del error de clasificación de los estados normal, ictal y postictal, para los vectores simples (DT y DWT) e híbridos (DT-DWT), sobre los clasificadores SVM, PNN y MLP, se presentan en las tablas 4.1, 4.2 y 4.3 respectivamente.



**Tabla 4.1.** Error de clasificación SVM de 3 estados (normal, ictal y postictal) para los vectores simples e híbridos.

PACIENTE	VECTOR DESCRIPTOR		
	DT	DWT	DT-DWT
1	17,71%	15,63%	9,38%
2	37,50%	45,83%	23,96%
3	27,08%	16,67%	21,88%
4	41,67%	60,42%	41,67%
5	12,50%	50%	9,38%
<b>PROMEDIO</b>	<b>27,292%</b>	<b>37,710%</b>	<b>21,254%</b>

**Tabla 4.2.** Error de clasificación PNN de 3 estados (normal, ictal y postictal) para los vectores simples e híbridos.

PACIENTE	VECTOR DESCRIPTOR		
	DT	DWT	DT-DWT
1	1,04%	0%	0%
2	2,08%	2,08%	2,08%
3	6,25%	26,04%	16,67%
4	16,67%	39,58%	21,88%
5	3,13%	0%	0%
<b>PROMEDIO</b>	<b>5,834%</b>	<b>13,540%</b>	<b>8,126%</b>

**Tabla 4.3.** Error de clasificación MLP de 3 estados (normal, ictal y postictal) para los vectores simples e híbridos

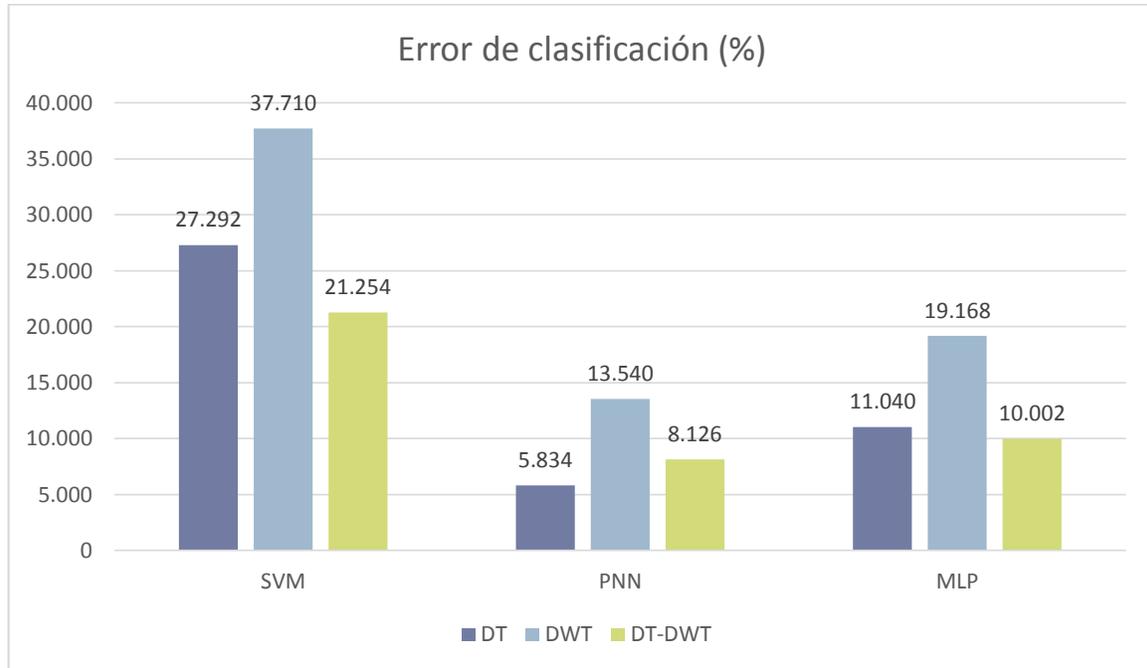
PACIENTE	VECTOR DESCRIPTOR		
	DT	DWT	DT-DWT
1	5,21%	7,29%	4,17%
2	6,25%	28,13%	7,29%
3	7,29%	3,13%	3,13%
4	31,25%	30,21%	29,17%
5	5,21%	27,08%	6,25%
<b>PROMEDIO</b>	<b>11,040%</b>	<b>19,168%</b>	<b>10,002%</b>

De las tablas previas, es posible corroborar que el error de clasificación es similar al de los promedios de Índice de Separabilidad de Clases (ver apéndice I, II), ya que los pacientes con mayor CSI, son los que presentan mayores errores en la clasificación de los estados y los de menor CSI, son los de menor error de clasificación. De lo anterior se concluye, que el Índice de Separabilidad de Clases permite determinar la capacidad que tiene una característica para diferenciar una clase de otra, por tanto, se considera un



mecanismo de reducción de dimensionalidad por selección de características confiable.

La figura 4.1, ilustra los errores promedio de clasificación en los estados normal, ictal y postictal para los vectores simples (DT y DWT) e híbridos (DT-DWT), sobre los clasificadores SVM, PNN y MLP.



**Figura 4.1.** Error promedio de clasificación de 3 estados para los vectores descriptores DT, DWT, DT-DWT.

Se puede observar que el menor error promedio para la clasificación de los estados normal, ictal y postictal, se presenta para el clasificador PNN, seguido de MLP. Por otra parte, se tiene que para los clasificadores SVM y MLP, el vector híbrido (DT-DWT) arroja menores errores de clasificación, que los simples; con lo que se concluye que un vector híbrido brinda una mejor caracterización de la señal EEG para 3 estados.

La matriz de *confusión* o *matriz de clasificación*, se utiliza para estimar los aciertos y errores producidos en los algoritmos de clasificación. Las filas corresponden a la clase a la que la señal pertenece, y las columnas a la clase



en la cual dicha señal fue clasificada. Las muestras que se clasifican correctamente se localizan en la diagonal principal. La figura 4.2, presenta la matriz de confusión correspondiente a uno de los clasificadores implementados, se puede visualizar que el estado postictal es el que presenta mayor error en su clasificación; de las 32 muestras, 17 clasifica correctamente, 10 confunde con el estado ictal y 5 con el normal. Cabe resaltar, que todos los pacientes presentan un comportamiento similar al que se observa en esta matriz.

	Normal	Ictal	Postictal
Normal	30	2	0
Ictal	3	21	8
Postictal	5	10	17

**Figura 4.2.** Matriz de confusión

Con lo anterior se deduce que el estado postictal es el que genera los errores de clasificación promedio más altos, es por esto que se decide también realizar la clasificación para 2 estados: normal e ictal.



### ➤ Error de clasificación para 2 estados (normal e ictal)

Los resultados del error de clasificación de los estados normal e ictal, para los vectores simples (DT y DWT) e híbridos (DT-DWT), sobre los clasificadores SVM, PNN y MLP, se presentan en las tablas 4.4, 4.5 y 4.6 respectivamente.

**Tabla 4.4.** Error de clasificación SVM de 2 estados (normal e ictal) para los vectores simples e híbridos.

PACIENTE	VECTOR DESCRIPTOR		
	DT	DWT	DT-DWT
1	0%	0%	0%
2	4,69%	1,56%	3,13%
3	0%	3,13%	3,13%
4	14,06%	29,69%	17,19%
5	0%	3,13%	3,13%
<b>PROMEDIO</b>	<b>3,750%</b>	<b>6,902%</b>	<b>5,316%</b>

**Tabla 4.5.** Error de clasificación PNN de 2 estados (normal e ictal) para los vectores simples e híbridos.

PACIENTE	VECTOR DESCRIPTOR		
	DT	DWT	DT-DWT
1	0%	0%	0%
2	3,13%	3,13%	3,13%
3	0%	0%	0%
4	3,13%	3,13%	1,56%
5	0%	0%	0%
<b>PROMEDIO</b>	<b>1,252%</b>	<b>1,252%</b>	<b>0,938%</b>

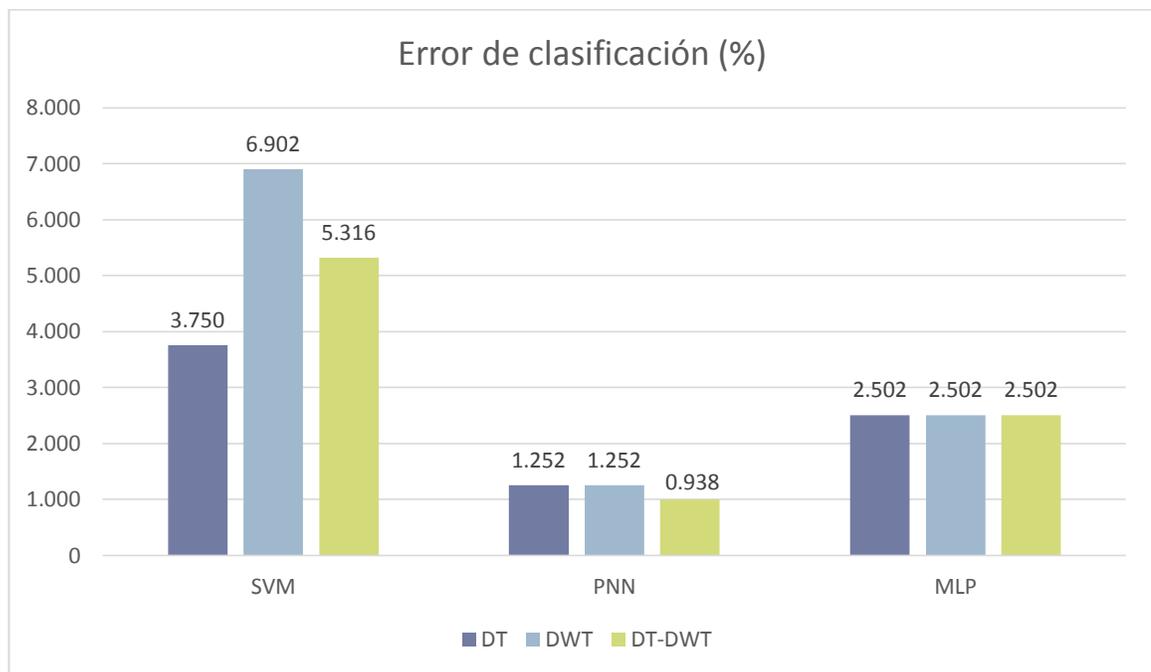
**Tabla 4.6.** Error de clasificación MLP de 2 estados (normal e ictal) para los vectores simples e híbridos.

PACIENTE	VECTOR DESCRIPTOR		
	DT	DWT	DT-DWT
1	0%	0%	0%
2	3,13%	0%	3,13%
3	0%	3,13%	0%
4	9,38%	0%	9,38%
5	0%	9,38%	0%
<b>PROMEDIO</b>	<b>2,502%</b>	<b>2,502%</b>	<b>2,502%</b>



Después de realizar la clasificación correspondiente a los dos estados (normal e ictal), los errores de clasificación disminuyeron notablemente, con lo que se comprobó que el estado postictal es el que genera los altos errores de clasificación. Una de las razones por la que puede suceder esto, es porque el estado postictal es continuo a las crisis, en donde la persona entra en una fase de recuperación que no es instantánea, y su estado emocional está aún alterado. Es por esto que el estado ictal y postictal, tienden a confundir las muestras clasificadas.

La figura 4.3, ilustra los errores promedio de clasificación de los estados normal, e ictal para los vectores simples (DT y DWT) e híbridos (DT-DWT), sobre los clasificadores SVM, PNN y MLP.



**Figura 4.3.** Error promedio de clasificación de 2 estados para los vectores descriptores DT, DWT, DT-DWT.

Se puede visualizar que el menor error promedio para la clasificación de los estados normal e ictal se presenta para el clasificador PNN, seguido de MLP. Por otra parte, se tiene que para el clasificador SVM, el vector descriptor simple DT es con el que se obtiene los menores errores de clasificación; para PNN



es el híbrido (DT-DWT) y MLP obtiene los mismos resultados para los tres tipos.

## 4.2. IMPLEMENTACIÓN DE ALGORITMOS Y FUNCIONES

En esta fase se describen las funciones más relevantes que se emplearon para la fase de clasificación de patrones.

### 4.2.1. Cuerpo Principal del Sistema

➤ Función: ***principal\_EEG.m***

Esta función recibe los vectores de características descriptores de cada estado, tanto para las características temporales como espectrales. Estos se utilizan finalmente para construir un solo vector de características por estado. Así mismo, entrega los resultados del sistema de extracción de características, los cuales se almacenan en una base de datos como archivos .mat. Cabe resaltar, que la información contenida en esta base de datos es la utilizada a posteriori para los sistemas clasificadores.

### 4.2.2. Algoritmo de Clasificación

➤ Función: ***algoritmos\_EEG.m***

La tarea principal de esta función es la de cargar los vectores de características, esto se realiza tanto en la base de datos de entreno, para el respectivo entrenamiento del clasificador, como para la base de datos de prueba en la clasificación de las señales EEG. Así mismo, se encarga de invocar las funciones de cada clasificador.



Las funciones implementadas para cada clasificador se presentan a continuación:

a) Clasificador SVM

➤ Función: **Algoritmo\_SVM.m**

*[resultado, conMat] = Algoritmo\_SVM (patrones\_entreno, patrones\_prueba, paciente)*

Las entradas: 'patrones\_entreno', corresponde a un arreglo matricial de los vectores híbridos de entrenamiento; 'patrones\_prueba', son los vectores híbridos de características EEGs, que se utilizan para el proceso de clasificación, y 'paciente' es la variable encargada de reconocer 1 de los 5 pacientes con el fin de cargar la red entrenada de cada uno de ellos. Las salidas 'resultado' y 'conMat' se refieren al porcentaje de error de clasificación y a la matriz de confusión respectivamente. La función **Algoritmo\_svm** invoca a **multiclase\_SVM** que es donde se crea, entrena y simula la red.

➤ Función: **multiclase\_SVM.m**

*function result = multiclase\_SVM (tr\_Set, ts\_Set, vec\_classes, paciente)*

'tr\_Set', contiene la matriz del conjunto de datos de entrenamiento de 96x10, la fila representa una observación de todas las muestras en un momento dado, mientras que cada columna corresponde a una característica; 'ts\_Set', contiene la matriz del conjunto de datos de prueba de 96x10; 'vec\_classes', es el vector que contiene la numeración de clases de cada muestra y 'paciente', es la variable encargada de reconocer 1 de los 5 pacientes.



**svmtrain.m.** Para crear y entrenar la red SVM [64].

```
models = svmtrain (tr_Set, class,'kernel_function','rbf', 'rbf_sigma', 1.3, 'boxconstraint',  
4)
```

**svmtrain.m** es una función propia de la librería de Matlab. Las entradas: 'tr\_Set', contiene la matriz del conjunto de datos de entrenamiento; 'class', se refiere a las etiquetas de clase que se le da a cada patrón de entrenamiento; 'kernel\_function', función kernel utilizada para mapear los datos de entrenamiento en un espacio kernel; 'rbf', Función Kernel de Base Radial Gaussiana; 'rbf\_sigma', es un parámetro con el cual se puede variar el área de error posible en la selección de clases y 'boxconstraint', constate de penalización C. La salida 'models', guarda la estructura de la red SVM.

Cabe resaltar que se probaron los diferentes tipos de función kernel, obteniendo los mejores resultados con RBF, para un valor de sigma ( $\sigma$ ) de 1.3 y constante de penalización 4. La variación de estos parámetros se realizó con el objetivo de obtener un buen desempeño de la SVM.

**svmclassify.m.** Para simular la red SVM [65].

```
temp = svmclassify (models ,ts_Set)
```

**svmclassify.m** es una función propia de la librería de Matlab. Las entradas: 'models', contiene la estructura generada para la red SVM y ts\_Set, la matriz del conjunto de datos de prueba. La salida 'temp', contiene la clasificación de cada muestra.

## b) Clasificador PNN

➤ Función: **Algoritmo\_PNN.m**

```
[resultado,conMat]=Algoritmo_PNN (patrones_entreno, patrones_prueba, paciente)
```



Las entradas: 'patrones\_entreno', corresponde a un arreglo matricial de los vectores híbridos de entrenamiento; 'patrones\_prueba', son los vectores híbridos de características EEGs, que se utilizan para el proceso de clasificación, y 'paciente' es la variable encargada de reconocer 1 de los 5 pacientes con el fin de cargar la red entrenada de cada uno de ellos. Las salidas 'resultado' y 'conMat' se refieren al porcentaje de error de clasificación y a la matriz de confusión respectivamente.

**newpnn.m.** Para crear y entrenar la red SVM [66]

*net = newpnn (P\_e, T, spread)*

**newpnn.m** es una función propia de la librería de Matlab. Las entradas: 'P\_e', son los patrones EEGs de entrenamiento; 'T', se refiere a las etiquetas de clase que se le da a cada patrón de entrenamiento y 'spread', es una variable que guarda la dispersión que se presenta en las funciones de base radial, es importante destacar que esta variable es un parámetro propio del clasificador PNN para su diseño, para este trabajo se toma un valor de spread=0.7.

Como variable de salida esta 'net', la cual posee la configuración del clasificador PNN.

**A = sim (net, P\_t)** Para simular la red PNN.

Las entradas: 'net', contiene la estructura de la red PNN y 'P\_t', son los patrones EEGs de prueba. La salida 'A', es una matriz de 3x96, correspondiente a la clasificación de cada muestra.

**c) Clasificador MLP**

➤ Función: **Algoritmo\_MLP.m**

*[resultado, conMat] = Algoritmo\_MLP (patrones\_entreno, patrones\_prueba, paciente)*



Las entradas: 'patrones\_entreno', corresponde a un arreglo matricial de los vectores híbridos de entrenamiento; 'patrones\_prueba', son los vectores híbridos de características EEGs, que se utilizan para el proceso de clasificación, y 'paciente' es la variable encargada de reconocer 1 de los 5 pacientes con el fin de cargar la red entrenada de cada uno de ellos. Las salidas 'resultado' y 'conMat' se refieren al porcentaje de error de clasificación y a la matriz de confusión respectivamente.

**feedforwardnet.m.** Para crear la red MLP [67].

```
net = feedforwardnet (hiddenSizes, trainFcn)
```

**feedforwardnet.m** es una función propia de la librería de Matlab. Las entradas: 'hiddenSizes', es un vector fila que contiene el tamaño de una o más capas ocultas, en este caso, se toma un vector con los siguientes valores [10 5 1] y 'trainFcn', es la función de entrenamiento, se elige trainlm. La salida 'net', guarda la estructura MLP que se va a entrenar.

**train.m.** Para entrenar la red MLP [68].

```
net = train(net, P_e, cd)
```

'net', corresponde a la red MLP creada; 'P\_e', entradas de la red y 'cd', objetivos de la red.



# CAPÍTULO 5.

## CONCLUSIONES Y TRABAJOS FUTUROS.

### 5.1. CONCLUSIONES

- En el procesamiento digital de señales biomédicas EEG, una herramienta de gran utilidad para su estudio y análisis es la teoría wavelet, que puede orientarse a la asistencia en el pronóstico médico en patologías como la epilepsia.
- En procesamiento de señales para efectos de reconocimiento de patrones, las fases de extracción de características y reducción de dimensionalidad son de suma importancia, ya que permiten obtener la información más significativa de la señal e influyen directamente en el desempeño del clasificador.
- La conformación de un vector híbrido de características DT-DWT brinda una mejor caracterización de la señal que un vector simple (DT o DWT), para clasificación de los tres (3) estados normal, ictal y postictal.
- El índice de separabilidad de clases (CSI), es un parámetro útil en la fase de reducción de dimensionalidad, ya que determina la capacidad



que tiene una característica para discriminar una clase de otra, lo que ayuda en la conformación de los vectores, además de permitir seleccionar los mejores pares de canales por paciente.

- Los clasificadores de aprendizaje basados en redes neuronales como PNN y MLP, presentan un mejor desempeño que los clasificadores de aprendizaje automático como SVM, ya que los de tipo neuronal permiten optimizar el error de clasificación mediante la manipulación de sus parámetros.
- De los resultados obtenidos en el error de clasificación para tres (3) estados (normal, ictal y postictal) y dos (2) estados (normal e ictal) se concluye que el estado postictal es el que genera los más altos errores de clasificación. Una de las razones por la que puede suceder esto es que el estado postictal es posterior a las crisis del ictal, en donde la persona entra en una fase de recuperación que no es instantánea y su estado emocional aún está alterado.
- La detección de los estados ictal y postictal presentes en pacientes epilépticos tiene gran importancia clínica, ya que el personal prehospitalario puede asistir al paciente de manera oportuna, evitando que algunos de los síntomas que se presentan durante estos estados comprometan su calidad de vida. En el estado ictal se puede prevenir traumas físicos, que se generan por los movimientos involuntarios durante las crisis y en el estado postictal que el paciente se comporte de forma peligrosa para él y para quienes lo rodean. Por otra parte, el estado postictal puede contribuir a localizar la región del cerebro donde se generó la crisis epiléptica, lo que es de gran ayuda en la evaluación pre- quirúrgica.



## 5.2. TRABAJOS FUTUROS

Como mejoras para un proyecto futuro, se propone:

1. Explorar otros métodos de clasificación que permitan determinar a partir de las características seleccionadas, a que estado pertenece cada muestra.
2. Probar los algoritmos desarrollados, con bases de datos elaboradas a partir de la toma de muestras de pacientes locales.





## REFERENCIAS

[1] © OMS 2016, “¿Qué son los trastornos neurológicos?,” [En línea] ONU, 2014. Disponible: <http://www.who.int/features/qa/55/es/>..[Consultado: 10 Noviembre 2015].

[2] © OMS 2016, “Epilepsia,” [En línea] ONU, 2015. Disponible: <http://www.who.int/mediacentre/factsheets/fs999/es/> [Consultado: 10 Noviembre 2015].

[3] A. Ceballos, “Detección de epilepsia en señales de electroencefalografía, mediante el uso de redes neuronales artificiales y máquinas con vectores de soporte,” Tesis de pregrado, Dep. Automática Electrónica, programa de Ingeniería Biomédica, Universidad Autónoma de Occidente, Santiago de Cali, Colombia, 2012.

[4] A. Ramírez, C. Augusto y E. Buitrago Bolívar, "Actualidad en la investigación de electroencefalograma-resonancia magnética funcional simultáneos en el estudio de epilepsia y dolor," *Revista Cubana de Investigaciones Biomédicas*, vol. 32, No. 1, pp. 29-47, 2013.

[5] C.E. Valderrama y G. Ulloa, “Análisis espectral de parámetros fisiológicos para la detección de emociones,” *Rev.S & T*, vol. 10, No. 20, pp. 27-49, (Enero-Marzo) 2012.

[6] C.N. Henríquez y F.B. Rodríguez, “Estudio de Técnicas de análisis y clasificación de señales EEG en el contexto de Sistemas BCI (Brain Computer Interface),” Tesis de maestría, Dep. Ingeniería Informática, Universidad Autónoma de Madrid, Madrid España, 2014.



- [7] R.A. Ramos, “Actualización clínica de las manifestaciones perictales e interictales epilépticas,” *Revista Electrónica Dr. Zoilo E. Marinello Vidaurreta*, vol. 40, No. 6, pp. 1-2, Junio 2015.
- [8] J.S. Agudelo, J.D. Cadavid, J. Giraldo, S.P. Muñoz, J.I. Ruiz y J.S. Serna, “Guía de atención prehospitalaria para el manejo del paciente con estatus epiléptico,” Tesis de pregrado, Dep. Emergencias y desastres-APH, Universidad CES, Medellín Colombia, 2015.
- [9] NINDS National Institute of Neurological Disorders and Stroke “Las epilepsias y las crisis: Esperanza en la investigación,” [En línea]. EEUU, 2015. Disponible: [http://espanol.ninds.nih.gov/trastornos/crisis\\_epilepticas.htm](http://espanol.ninds.nih.gov/trastornos/crisis_epilepticas.htm). [Consultado: 1 Enero 2016].
- [10] L. Vijayaraghavan, S. Natarajan y E.S. Krishnamoorthy, “Peri-ictal and ictal cognitive dysfunction in epilepsy,” *Behav neurol*, vol. 24, No. 1, pp. 27-34, 2011.
- [11] C. Pérez y W.B. Barr, “Neuropsicología en epilepsia,” *Revista Médica Clínica Las Condes*, vol. 24, No. 6, pp. 987-994, septiembre, 2013.
- [12] Encyclopædia Britannica, “Electroencephalography,” [En línea]. Inglaterra, 2014. Disponible: <http://global.britannica.com/science/electroencephalography>. [Consultado: 1 Enero 2016].
- [13] A.L. García, “El sistema nervioso,” [en línea]. Universidad Autónoma de Madrid, 2006. Disponible en: [https://www.uam.es/personal\\_pdi/medicina/algvillafundamentos/nervioso.htm](https://www.uam.es/personal_pdi/medicina/algvillafundamentos/nervioso.htm). [Consultado: 2 Enero 2016].
- [14] K. Linares, F. Guilarte y R. Aponte, “Funcionamiento de una Neurona Biológica,” [En línea] 2012. Disponible en: [http://redesneuronalesuba.blogspot.com.co/2012\\_11\\_01\\_archive.html](http://redesneuronalesuba.blogspot.com.co/2012_11_01_archive.html). [Consultado: 2 Enero 2016].
- [15] L.N. Jaramillo, “Electroencefalografía cuantitativa,” [En línea]. División de ciencias de la salud. Universidad de Quintana, 2010. Disponible: <http://dcs.uqroo.mx/electroencefalografia>. [Consultado: 4 Enero 2016].



- [16] M. Torres, J. L. Bustos y F. Granados, “Fisiopatología del estatus epiléptico,” *Acta Neurológica Colombiana*, vol. 27, No. 1, pp. 11-20, diciembre, 2011.
- [17] J. Malmivuo y R. Plonsey, “Electroencephalography,” en *Bioelectromagnetism, Principles and Applications of Bioelectric and Biomagnetic Fields*, oxford University Press, New York, 1995, pp. 257-264.
- [18] E. Millán, C. Jiménez, D. Ospina y O. Henao, “Characterization of the EEG sensor BR8 plus: Steady-state and Theta and Beta rhythms verification using the Stroop effect for visual attention,” *Actas de Ingeniería*, vol. 1, pp. 66-71, 2015.
- [19] I. Mora y A. Torres, “Detección de crisis epilépticas a partir de señales EEG mediante índices basados en el algoritmo de Lempel-Ziv,” Tesis de pregrado, Dep. Electrónica Industrial y Automática, Escuela Politécnica Superior de Ingeniería de Vilanova y la Geltrú, 2013.
- [20] B. López, A. Úbeda, D. Planelles, C. Perez-Vidal, E. Iáñez y J. M. Azorín, “Aplicación de ICA para la eliminación de artefactos oculares y mandibulares en señales EEG durante la realización de tareas mentales,” *Actas de las XXXV Jornadas de Automática*, pp. 1-6, septiembre, 2014.
- [21] G. Repovš, “Dealing with noise in EEG recording and data analysis,” *Informatica Medica Slovenica*, vol. 15, No. 1, pp. 18-25, Agosto, 2010.
- [22] M. Shoaib, N.K. Jha y N. Verma, “Enabling advanced inference on sensor nodes through direct use of compressively-sensed signals,” *Proc. IEEE, Design, Automation, and Test in Europe Conf*, Marzo, 2012, pp. 437-443.
- [23] PhysioNet, “chb-mit scalp EEG database,” [En línea] National Institute of General Medical Sciences (NIGMS), National Institute of Biomedical Imaging and Bioengineering (NIBIB), 2015. Disponible en: <http://www.physionet.org/physiobank/database/chbmit/>. [Consultado: 7 Marzo 2016].



[24] A.L. Goldberger, L. Glass, J.M. Hausdorff, P.Ch. Ivanov, R.G. Mark, J.E. Mietus, G.B. Moody, C.K Peng, H.E. Stanley,” PhysioBank, PhysiToolkit, and Physionet: Components of a New Research Resource for Complex Physiologic Signals,” [En línea] *Circulation Electronic Pages*, vol. 101, pp. 215-220, Junio 2000. Disponible: <http://circ.ahajournals.org/cgi/content/full/101/23/e215>. [Consultado: 7 Marzo 2016].

[25] J. P Marques de Sa, “Pattern Discrimination,” en *Pattern recognition: concepts, methods and applications*, Springer, New York, 2012, pp. 21-49.

[26] H. A. Romo y P.E. Jojoa, “Aplicación de wavelets en el análisis y la extracción de características para la clasificación de señales EMGs,” Tesis de maestría, Dep. Telecomunicaciones, Universidad del Cauca, Popayán, Colombia, 2008.

[27] A.C. Vinzio, A. Garcés, L. Orozco y E. Laciari “Detección de crisis ictales en registros EEG de pacientes epilépticos usando análisis temporal y frecuencial,” de XVIII Congreso Argentino de Bioingeniería SABI, Mar del Plata, 2011.

[28] D. Gajic, Z. Djurovic, J. Gligorijevic, S. Di Gennaro y I. Savic, “Detection of epileptiform activity in EEG signals based on time-frequency and non-linear analysis,” *Frontiers in computational neuroscience*, vol. 9, No. 38, pp. 1-16, Marzo, 2015.

[29] M. Kalaivani, V. Kalaivani y V. Devi, “Analysis of EEG Signal for the Detection of Brain Abnormalities,” *International Journal of Computer Applications*®, ICSCN, No. 2, pp. 1-6, Junio 2014.

[30] L. Boubchir, S. Al-Maadeed y A. Bouridane, “On the use of time-frequency features for detecting and classifying epileptic seizure activities in non-stationary EEG signals,” *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP'2014)*, 2014, pp. 5909-5913.

[31] P.R. Marchena y M.A Díaz, “Implementación y validación de un modelo matemático de señales de EEG de pacientes epilépticos en una plataforma



DSP,” Tesis de Magister, Dep. Ingeniería Biomédica, Universidad Simón Bolívar, 2010.

[32] D. Wayne y C. Chad,” Descriptive Statistics,” en *Biostatistics: A Foundation for Analysis in the Health Sciences*, ed. J. Wiley y Sons, New York, 2012, pp. 19 -63.

[33] J. P Marques de Sa, “Presenting and Summarising the Data,” en *Applied statistics using SPSS, statistica, Matlab and R*, Springer, New York, 2007, pp. 29-77.

[34] P. Faundez, A. Fuentes, "Procesamiento Digital de Señales Acústicas utilizando Wavelets," Tesis de pregrado, Dep. Instituto de Matemáticas UACH, Chile, 2002.

[35] R. J. Medina, C. Pinilla, L. Joyanes, “Reconstrucción de una señal sinusoidal y de una imagen sintética usando la transformada de wavelet discreta,” *Ninth LACCEI Latin American and Caribbean Conference (LACCEI'2011), Engineering for a Smart Planet, Innovation, Information Technology and Computational Tools for Sustainable Development*, Medellín, Agosto 3-5, 2011.

[36] J. Martínez y R.M. Castro, “Análisis de la teoría de ondículas orientada a las aplicaciones en ingeniería eléctrica: Fundamentos,” Tesis de Maestría, Dep. Ingeniería Eléctrica, Universidad Politécnica de Madrid, ETSI industriales, Madrid, 2002.

[37] J.M. Macchi, L. De Pasquale, M.A. Banchieri, “Análisis Basado en la Transformada Wavelet para Determinar Duración de Transitorios en Señales,” *IV Congreso Microelectrónica Aplicada* pp. 170-174, septiembre, 2013.

[38] C. Guarnizo, “Análisis de reducción de ruido en señales EEG orientado al reconocimiento de patrones,” *Revista Tecnológicas*, No. 21, pp. 67-80, Diciembre, 2008.



[39] G. Luna-Guevara, "Reducción de ruido en señales de electroencefalograma: una aplicación para mejorar las imágenes de mapeo cerebral," *Rev Electronic Journal of Biomedicine*, vol. 3, pp. 18-25, 2014.

[40] U.R Acharya, F. Molinari, S.V. Sree, S. Chattopadhyay, K.H. Ng y J.S. Suri "Automated diagnosis of epileptic EEG using entropies," en *Biomedical Signal Processing and Control* 7, 2012, pp. 401-408.

[41] M.J. Seguí, "Study on the non-linear metrics contribution to estimate atrial fibrillation organization from the surface electrocardiogram," Tesis doctoral, Dep. de Ingeniería Electrónica, Universidad Politécnica de Valencia, Valencia, 2015.

[42] S. Valencia y E.A. Cano, "Evaluación de la calidad de la potencia eléctrica, mediante la medición de entropía del campo magnético radiado en inmediaciones al transformador," Tesis de maestría, Dep. de Ingeniería Eléctrica, Electrónica y Computación, Universidad Nacional de Colombia-Sede Manizales, 2014.

[43] B.S. Aghazadeh, "Traumatic brain injury assessment using the integration of pattern recognition methods and finite element analysis," Tesis doctoral, Dep. de Ingeniería Mecánica, Universidad de la Mancomunidad de Virginia, Richmond Virginia, 2012.

[44] D. A. Torres y R. Weber, "Diseño y aplicación de una metodología para análisis de noticias policiales utilizando minería de textos," Tesis de pregrado, Dep. de Ingeniería Industrial, Universidad de Chile, Santiago de Chile, 2013.

[45] J.I. Fernandez, M. Hurtado, J.A. Areta y C.H Muravchik, "Polarimetric SAR Image Segmentation using CEM Algorithm," *Latin America Transactions, IEEE (Revista IEEE America Latina)*, vol. 12, No. 5, pp. 910-914, Agosto, 2014

[46] O.E. Gualdron, E. Llobet y J. Brezmes "Desarrollo de diferentes métodos de selección de variables para sistemas multisensoriales," Universidad de Rovira y Virgili, Escuela Técnica Superior de Ingeniería, Tarragona España, 2010, pp. 68-99. ISBN: 9788469340707.



- [47] P. Fergus, A. Hussain, D. Hignett, D. Al-Jumeily, K. Abdel-Aziz y H. Hamdan, "A machine learning system for automated whole-brain seizure detection," *Applied Computing and Informatics*, vol. 12, No. 1, pp. 70-89, Enero, 2016.
- [48] M. Singh y S. Kaur, "Epilepsy detection using EEG: An overview," *International Journal of Information Technology and Knowledge Management*, vol. 6, No. 1, pp. 3-5, Diciembre, 2012.
- [49] J.J. Mora, "Localización de faltas en sistemas de distribución de energía eléctrica usando métodos basados en el modelo y métodos basados en el conocimiento," Tesis Doctoral, Dep. Tecnologías de la Información, Universitat de Girona, 2006.
- [50] M. Hariharan, S. Yaacob y S. Ardeenaawatie, "Pathological infant cry analysis using wavelet packet transform and probabilistic neural network," *Expert Systems with Applications*, vol. 38, No. 12, pp. 15377-15382, Noviembre, 2011.
- [51] M. Castillo, "Evaluación del desempeño de dos modelos de redes neuronales artificiales para clasificar flores de *Petunia spp* con base en color," Tesis maestría, Dep. de Socioeconomía, Estadística e informática, Institución de Enseñanza e Investigación en Ciencias Agrícolas, Montecillo, Texcoco, 2013.
- [52] J. Ramírez y M. Chacón, "Redes neuronales artificiales para el procesamiento de imágenes, una revisión de la última década," *Revista de Ingeniería Eléctrica, Electrónica y Computación*, vol. 9, No.1, pp. 7-16, 2011.
- [53] L. Salas y J.D. Velásquez "Análisis de la actividad cerebral medida a partir de un electroencefalograma como variable predictiva de la toma de decisión de un usuario web," Tesis de pregrado, Dep. Ingeniería Industrial, Universidad de Chile, Santiago de Chile, 2014.
- [54] P.E. Méndez y J. Ibarra, "Implementación de un sistema de identificación de poses en imágenes de rostros," Tesis de maestría, Universidad San Francisco de Quito, Quito, 2013.



[55] R. Zavala, R. Ramírez y L. M. Cordero, "Novel way to investigate evolution of children refractory epilepsy by complexity metrics in massive information," *SpringerPlus* vol. 4, No. 1, pp. 1-33, Agosto, 2015.

[56] MathWorks, "Wavelet Toolbox", [En línea] Estados Unidos, 2016. Disponible: <http://www.mathworks.com/products/wavelet/>. [Consultado: 30 Junio 2016].

[57] D.M. Lara, M.C. Olaya y J.A. Cuartas "Sistema de reconocimiento de patrones de potenciales evocados visuales de estado estacionario," Tesis de pregrado, Dep. de Ingeniería Biomédica, Universidad CES, Medellín, 2013

[58] J.L. Sánchez, "Descripción del funcionamiento de un módulo clasificador de ondas electroencefalográficas utilizando la plataforma OpenVibe," Tesis de pregrado, Dep. de Ingeniería Eléctrica, Universidad de Costa Rica, Ciudad Universitaria Rodrigo Facio, 2011.

[59] I.Omerhodzic, S. Avdakovic, A. Nuhanovic y K. Dizdarevi, "Energy distribution of EEG signals: EEG signal wavelet-neural network classifier," *International Journal of Biological and Life Sciences*, vol. 6, No. 4, pp. 210-216, 2010.

[60] Y.U. Khan, O. Farooq y P. Sharma, "Automatic detection of seizure onset in pediatric EEG," *International Journal of Embedded Systems and Applications*, vol. 2, No. 3, pp. 81-89, 2012.

[61] N. Mammone, F. La Foresta y F. Morabito, "Automatic artifact rejection from multichannel scalp EEG by wavelet ICA," *IEEE Sensors J.*, vol. 12, No. 3, pp. 533-542, Marzo, 2012.

[62] P. Ataee, A. N. Avanaki, H. F. Shariatpanahi y S.M Khoei, "Ranking features of wavelet-decomposed EEG based on significance in epileptic seizure prediction," in *Proc. of the 14th European Signal Processing Conference*, pp. 1-4, Florencia, Italia, Sep. 3-10, 2006.



[63] A.N. Bermúdez, “Técnicas de procesamiento de EEG para detección de eventos,” Tesis Maestría, Dep. Electrotecnia, Universidad Nacional de La Plata, Buenos Aires, Argentina, 2014.

[64].MathWorks, “svmtrain”, [En línea] Estados Unidos, 2016. Disponible: <http://www.mathworks.com/help/stats/svmtrain.html>. [Consultado: 11 Julio 2016].

[65].MathWorks, “svmclassify”, [En línea] Estados Unidos, 2016. Disponible: <http://www.mathworks.com/help/stats/svmclassify.html>. [Consultado: 7 Marzo 2016].

[66] MathWorks, “newpnn”, [En línea] Estados Unidos, 2016. Disponible: <http://www.mathworks.com/help/nnet/ref/newpnn.html>. [Consultado: 11 Julio 2016].

[67] MathWorks, “feedforwardnet”, [En línea] Estados Unidos, 2016. Disponible: <http://www.mathworks.com/help/nnet/ref/feedforwardnet.html>. [Consultado: 11 Julio 2016].

[68].MathWorks, “train”, [En línea] Estados Unidos, 2016. Disponible: <http://www.mathworks.com/help/nnet/ref/train.html>. [Consultado: 11 Julio 2016].





## ANEXOS

### Anexo A. Información de la base de datos.

En la tabla A.1 se ilustra los 23 canales con sus respectivos pares de electrodos. Esta configuración se emplea para los pacientes 1, 3 y 5.

**Tabla A.1.** Configuración de canales según el sistema internacional 10-20, para los pacientes 1, 3 y 5. Adaptada de [23]

Canal	Electrodos
1	FP1-F7
2	F7-T7
3	T7-P7
4	P7-O1
5	FP1-F3
6	F3-C3
7	C3-P3
8	P3-O1
9	FP2-F4
10	F4-C4
11	C4-P4
12	P4-O2
13	FP2-F8
14	F8-T8
15	T8-P8
16	P8-O2
17	FZ-CZ



18	CZ-PZ
19	P7-T7
20	T7-FT9
21	FT9-FT10
22	FT10-T8
23	T8-P8

En la tabla A.2 se ilustra los 28 canales con sus respectivos pares de electrodos. Esta configuración se emplea para el paciente 2 y 4.

**Tabla A.2.** Configuración de canales según el sistema internacional 10-20, para el pacientes 2 y 4. Adaptada de [23]

Canal	Electrodos
1	FP1-F7
2	F7-T7
3	T7-P7
4	P7-O1
5	-
6	FP1-F3
7	F3-C3
8	C3-P3
9	P3-O1
10	-
11	FZ-CZ
12	CZ-PZ
13	
14	FP2-F4
15	F4-C4
16	C4-P4
17	P4-O2
18	-
19	FP2-F8
20	F8-T8
21	T8-P8
22	P8-O2
23	-
24	P7-T7
25	T7-FT9
26	FT9-FT10



27	FT10-T8
28	T8-P8

En la tabla A.3 se ilustra información de la edad y sexo correspondiente a los 5 pacientes de la base de datos.

**Tabla A.3.** Edad y sexo de los registros de la base de datos. Adaptada de [23]

PACIENTE	GENERO	EDAD
1	F	11
2	F	6
3	F	14
4	F	9
5	F	7



**ANÁLISIS DE SEÑALES EEG CON REGISTROS DE EPILEPSIA MEDIANTE  
RECONOCIMIENTO DE PATRONES Y TRANSFORMADA WAVELET**



**APÉNDICE I y II**

Lina Andrea Arcila Armero  
Liceth Yuliana Cajas Hoyos

*Universidad del Cauca*

**Facultad de Ingeniería Electrónica y de Telecomunicaciones  
Departamento de Telecomunicaciones  
Grupo Nuevas Tecnologías en Telecomunicaciones GNTT  
Popayán, Agosto de 2016**



## CÁLCULO DE LOS PROMEDIOS CSI PARA LOS PARÁMETROS TEMPORALES.



### APÉNDICE I

Lina Andrea Arcila Armero  
Liceth Yuliana Cajas Hoyos

Director: MSc. Harold Armando Romo Romero

*Universidad del Cauca*

Facultad de Ingeniería Electrónica y de Telecomunicaciones  
Departamento de Telecomunicaciones  
Grupo Nuevas Tecnologías en Telecomunicaciones GNTT  
Popayán, Agosto de 2016





## APÉNDICE I. CÁLCULO DE LOS PROMEDIOS CSI PARA LOS PARÁMETROS TEMPORALES.

A continuación se ilustran los promedios CSI obtenidos para los parámetros temporales.

**Tabla I.1.** Promedios CSI para el parámetro media evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
1	295,3473	34,0691	40,7593	26,4718	13,4744
2	168,2478	15,0296	88,7040	14,3468	14,9915
3	57,9754	49,6729	8,8776	94,9075	17,8121
4	97,8618	10,5116	12,8766	16,9041	13,7661
5	34,5520	-	96,5013	-	130,5962
6	222,9299	9,6750	41,2575	129,4829	12,4489
7	83,4512	24,1092	36,3635	31,0784	9,9717
8	40,7096	24,4620	9,2557	85,8900	16,7984
9	31,4096	13,9244	430,4894	20,3440	21,2620
10	36,6024	-	82,9292	-	16,2821
11	11,5311	24,8867	26,1920	21,9115	15,2603
12	10,5369	7,9408	11,7011	40,6089	12,6441
13	24,8180	-	109,0794	-	74,9883
14	133,3971	9,7431	34,8404	52,4389	24,5208
15	22,4501	17,6433	21,3783	12,1194	9,9240
16	78,6335	7,9296	28,5210	20,0781	6,9509
17	100,6884	22,2888	65,6825	13,9919	9,8174
18	30,3948	-	22,9566	-	7,4214
19	57,9754	6,7473	8,8776	12,7071	17,8121



<b>20</b>	1,2418 e <sup>3</sup>	13,3483	124,5632	23,1870	18,3880
<b>21</b>	280,3178	16,3186	53,0233	21,5983	21,0089
<b>22</b>	28,7260	48,6861	113,4674	7,8380	20,1761
<b>23</b>	0,0481	-	21,3783	-	9,9240
<b>24</b>		49,6729		94,9075	
<b>25</b>		39,2159		25,1811	
<b>26</b>		43,2586		210,9339	
<b>27</b>		47,7067		11,5549	
<b>28</b>		16,3186		21,5983	

**Tabla I.2.** Promedios CSI para el parámetro varianza evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
<b>1</b>	0,6239	1,2085	17,8303	4,3037	0,9052
<b>2</b>	0,4986	4,7917	1,2625	3,2214	1,0877
<b>3</b>	0,7350	2,3331	0,4298	1,8072	4,6520
<b>4</b>	0,8363	2,4162	0,6083	3,0374	0,4837
<b>5</b>	0,6641	-	3,6911	-	0,5044
<b>6</b>	0,5626	2,8110	1,5347	1,4548	1,0163
<b>7</b>	0,7126	3,4915	0,6042	1,0236	0,9773
<b>8</b>	0,8614	1,1126	0,7522	3,5202	0,7930
<b>9</b>	0,5563	2,2161	1,8031	1,5471	0,5640
<b>10</b>	0,4922	-	3,5214	-	1,2660
<b>11</b>	0,7519	2,3916	1,2217	0,9577	21,2442
<b>12</b>	0,9279	1,8661	0,9608	2,3616	2,0535
<b>13</b>	0,6594	-	1,4250	-	0,6901
<b>14</b>	0,6028	1,5839	6,6973	1,9434	12,1487
<b>15</b>	0,5468	2,2259	0,5767	1,3261	1,7193
<b>16</b>	0,8249	2,3544	1,1231	1,3682	1,0739
<b>17</b>	0,6552	5,7990	29,5380	6,6682	0,8009



<b>18</b>	1,0160	-	0,8379	-	2,6630
<b>19</b>	0,7350	1,6028	0,4298	1,3779	4,6520
<b>20</b>	0,6158	3,3876	0,5240	1,7170	3,7231
<b>21</b>	0,6183	1,1314	0,7456	3,6255	0,6475
<b>22</b>	0,5239	2,5250	0,8050	3,2441	1,8997
<b>23</b>	0,5468	-	0,5767	-	1,7193
<b>24</b>		2,3331		1,8072	
<b>25</b>		3,3345		1,6583	
<b>26</b>		1,6630		10,4384	
<b>27</b>		0,8352		10,3836	
<b>28</b>		1,1344		3,6255	

**Tabla I.3.** Promedios CSI para el parámetro desviación estándar evaluado en cada canal para los 5 pacientes. Por los autores.

<b>CANAL</b>	<b>PACIENTE 1</b>	<b>PACIENTE 2</b>	<b>PACIENTE 3</b>	<b>PACIENTE 4</b>	<b>PACIENTE 5</b>
<b>1</b>	0,4688	1,0576	4,3902	3,6745	0,8531
<b>2</b>	0,3707	1,7997	0,9805	2,0056	1,2395
<b>3</b>	0,6244	1,5257	0,3392	4,3707	6,7702
<b>4</b>	0,7286	1,8922	0,4858	3,9564	0,4109
<b>5</b>	0,5169	-	2,2201	-	0,4347
<b>6</b>	0,4214	2,5472	1,1441	2,3944	0,5652
<b>7</b>	0,6036	6,4578	0,4332	0,8977	0,8490
<b>8</b>	0,7777	0,9366	0,5551	1,4019	0,6861
<b>9</b>	0,4479	1,7959	2,9197	1,2676	0,4691
<b>10</b>	0,3732	-	2,3668	-	0,6784
<b>11</b>	0,6411	2,1952	0,8151	0,8057	1,7220
<b>12</b>	0,8847	1,5687	0,6152	3,1937	0,9876
<b>13</b>	0,5097	-	1,4484	-	0,6624
<b>14</b>	0,4546	1,5403	1,9377	4,0764	43,7313
<b>15</b>	0,4121	1,7632	0,4480	1,0096	1,4395
<b>16</b>	0,7085	3,5869	0,6711	1,1038	0,7921



17	0,5368	8,2218	2,5245	1,7044	0,4860
18	0,8096	-	0,7638	-	0,6279
19	0,6244	1,4118	0,3392	1,4450	6,7702
20	0,4795	1,6014	0,4280	1,6680	63,8552
21	0,4828	1,0945	0,5611	1,9445	0,5887
22	0,4378	2,0878	0,6764	10,7160	2,0685
23	0,4121	-	0,4480	-	1,4395
24		1,5257		4,3707	
25		4,4748		2,1506	
26		1,2586		3,2909	
27		0,7618		5,1173	
28		1,0945		1,9445	

**Tabla I.4.** Promedios CSI para el parámetro Asimetría evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
1	5,7652	10,5526	1,9793	19,7097	7,1321
2	38,1449	22,9562	3,4581	2,1897	17,8728
3	7,5965	4,3233	5,7873	9,4671	2,6937
4	10,2657	5,7187	3,4483	13,5833	5,3806
5	3,0273	-	6,4826	-	2,3163
6	4,6853	24,0714	6,0066	17,2526	2,8680
7	17,2823	3,7612	7,3713	5,9403	27,0422
8	2,7412	5,9622	5,0854	4,1097	13,7746
9	4,2477	93,0983	31,1898	13,3612	8,7856
10	275,0399	-	7,2384	-	3,4433
11	57,1531	63,1331	32,0215	6,2591	5,8992
12	2,7245	3,3261	4,9460	3,9615	100,3332
13	5,8051	-	8,8096	-	3,5924
14	4,4835	16,2181	3,8110	11,7875	6,3851
15	4,5706	2,6175	3,5749	5,4952	3,2608



16	23,6251	3,1157	6,5534	3,2324	3,6969
17	28,8948	22,7786	3,2302	4,8926	17,1605
18	22,4742	-	2,6601	-	83,5327
19	7,5965	9,3512	5,7873	65,3472	2,6937
20	3,1205	3,9848	24,5954	7,0959	2,7232
21	3,5462	10,9985	3,2488	5,0940	9,6174
22	22,6900	8,2104	54,0210	5,2578	7,0609
23	4,5706	-	3,5749	-	3,2608
24		4,3233		9,4671	
25		6,0625		4,7148	
26		177,2207		9,3913	
27		28,3825		3,3272	
28		10,9985		5,0940	

**Tabla I.5.** Promedios CSI para el parámetro curtosis evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
1	8,0006	2,1268	6,4559	4,2631	2,9465
2	5,9437	2,2712	2,1289	2,5673	1,9862
3	2,8607	4,2677	4,3019	4,2019	3,8442
4	3,7495	12,7654	2,3575	4,1251	2,0484
5	6,8324	-	5,7654	-	4,5800
6	8,8717	1,7279	7,0282	51,1795	2,9946
7	4,5682	4,1767	4,9060	17,1319	9,9634
8	3,7168	13,2701	6,0758	2,9726	6,7725
9	40,5567	25,5504	8,2032	11,0157	8,8959
10	11,5224	-	4,2692	-	2,1218
11	10,8006	25,2796	3,6893	84,7535	5,4939
12	3,8818	5,7995	3,9231	3,2747	1,8846
13	4,5216	-	6,5083	-	2,0464
14	7,5177	10,3050	4,3441	8,2037 e <sup>3</sup>	15,9754



15	5,6298	36,2943	3,5691	8,9040	2,3618
16	9,6069	7,1304	4,1584	6,0686	3,4224
17	3,9104	7,2931	2,3671	584,4424	2,1730
18	3,8823	-	6,5984	-	4,2103
19	2,8607	1,6791	4,3019	2,3006	3,8442
20	20,5524	6,3552	3,8386	66,7811	7,2385
21	40,3973	2,3032	2,0011	1,8219	2,3281
22	61,5073	17,4384	4,9225	4,1421	4,6529
23	5,6298	-	3,5691	-	2,3618
24		4,2677		4,2019	
25		2,6121		4,2704	
26		43,7621		21,2823	
27		1,1016		7,2506	
28		2,3032		1,8219	

**Tabla I.6.** Promedios CSI para el parámetro coeficiente de variación evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
1	5,6740	9,4852	16,5647	7,4756	22,0733
2	16,1668	4,8008	3,2580	5,0408	8,4769
3	3,8475	6,0490	395,7732	15,9679	3,2577
4	7,1578	13,2506	28,5238	18,5187	30,0358
5	4,3990	-	52,4240	-	3,1120
6	7,8937	6,6689	5,0811	3,7052	8,3137
7	3,4194	16,5120	14,8042	21,1726	4,4377
8	6,7070	4,1602	2,9665	3,0804	16,4957
9	2,9251	3,1040	2,8245	3,7804	8,1503
10	3,6792	-	69,7319	-	8,8620
11	17,8520	3,6336	12,4223	19,9570	3,8240
12	6,6911	3,1257	35,1712	6,3000	4,4052



13	4,3542	-	23,0899	-	3,4893
14	34,9871	47,7699	5,3559	8,3244	13,8429
15	17,7198	8,7332	13,1525	5,8148	10,9993
16	5,2385	4,6558	-	14,8427	18,7558
17	3,0723	12,4433	5,7685	3,3381	10,2738
18	6,2406	-	13,8692	-	34,4798
19	3,8475	4,6421	395,7732	7,1970	3,2577
20	8,7697	17,8437	7,3852	4,7565	2,8281
21	7,1400	20,9659	20,1568	9,5353	3,5871
22	14,7680	9,8532	4,0990	11,8689	12,5763
23	17,7198	-	13,1525	-	10,9993
24		6,0490		15,9679	
25		46,5311		39,1742	
26		16,6027		108,8393	
27		6,2248		9,0954	
28		20,9659		9,5353	

**Tabla I.7.** Promedios CSI para el parámetro VMA evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
1	0,4608	1,0831	6,4423	6,9432	0,7772
2	0,4227	2,2483	0,9860	1,9950	1,5889
3	0,7335	1,3668	0,3446	6,3539	4,4781
4	0,7854	1,4955	0,6202	20,3981	0,3998
5	0,5054	-	2,7481	-	0,3819
6	0,4325	2,6391	0,9804	2,2164	0,4484
7	0,5707	7,5174	0,4510	0,9155	0,7812
8	0,7678	0,8066	0,5802	1,2366	0,6564
9	0,4703	1,5659	2,5746	2,0074	0,4566
10	0,3943	-	1,4503	-	0,5346
11	0,6479	2,2598	0,7652	0,8220	1,1618



12	0,9692	1,3200	0,7122	3,6571	0,7703
13	0,6118	-	1,3800	-	0,6995
14	0,5692	1,4488	2,9121	3,2211	3,2560
15	0,4448	1,8416	0,4592	1,0849	1,5281
16	0,7236	1,9997	0,6835	1,5824	0,7159
17	0,5125	4,7025	1,6735	4,3923	0,4208
18	0,7756	-	0,7348	-	0,5711
19	0,7335	1,4537	0,3446	1,1748	4,4781
20	0,5366	1,6130	0,4608	1,8775	3,3353
21	0,4976	1,1512	0,6226	1,4786	0,6341
22	0,5082	2,1225	0,7271	5,2535	8,2356
23	0,4448	-	0,4592	-	1,5281
24		1,3668		6,3539	
25		9,0637		1,5721	
26		1,2507		3,2170	
27		0,8035		3,8074	
28		1,1512		1,4886	

**Tabla I.8.** Promedios CSI para el parámetro CC evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
1	0,8086	1,0034	1,7076	1,2789	0,3819
2	3,2469	1,0567	1,1974	1,6249	28,8006
3	1,8504	1,1621	0,8650	1,0033	0,7382
4	63,2725	2,2141	9,4290	0,7294	1,0492
5	1,1844	-	1,3249	-	0,6586
6	1,2642	1,1098	1,4645	1,8903	0,6406
7	1,7246	1,0366	5,6943	1,3476	0,7313
8	1,6664	1,3540	1,0825	0,9574	0,7763
9	2,2408	7,1324	2,1490	0,7282	0,7888
10	1,9226	-	2,8808	-	2,7390



11	3,5290	1,1191	1,1852	2,6421	1,2537
12	37,3583	3,9299	1,0392	1,2633	3,6900
13	1,3777	-	2,4411	-	0,4618
14	14,4400	1,7386	187,9484	7,3071	3,0340
15	0,7082	2,2139	1,7779	1,1406	2,0472
16	8,4363	50,5945	1,1417	1,2111	0,7739
17	28,8947	2,6207	2,0743	0,6195	0,6590
18	2,0555	-	1,5245	-	0,5374
19	1,4003	6,4712	0,8130	4,2342	1,4391
20	58,4383	8,6281	1,0715	0,9867	4,6106
21	2,6799	5,1738	1,7813	0,6832	0,4363
22	0,8453	5,1308	0,9360	0,6117	1,3214
23	0,7082	-	1,7779	-	2,0472
24		0,8702		0,9962	
25		6,7807		1,8923	
26		0,7455		1,1878	
27		1,4418		0,7590	
28		5,1738		0,6832	

**Tabla I.9.** Promedios CSI para el parámetro CSP evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
1	2,2946	3,9765	1,6031	1,2812	2,0499
2	1,1851	2,2453	1,6542	15,2072	0,4142
3	1,0060	0,7955	2,6754	1,1498	0,5553
4	0,6547	5,8165	6,1761	0,6927	0,5885
5	1,3165	-	108,1111	-	0,9763
6	0,9453	1,6663	2,4912	1,1868	0,4286
7	1,8472	0,9280	3,8100	0,7406	0,5527
8	2,9356	0,9509	6,2634	0,6696	0,5262



9	0,9197	2,1381	1,9763	0,5778	0,8355
10	0,6075	-	2,5007	-	0,4750
11	0,7565	1,7999	1,2340	0,6804	0,3653
12	5,1466	1,4742	3,3964	0,5851	0,4876
13	1,4707	-	2,7651	-	6,0510
14	0,9638	1,4596	4,5115	17,2173	0,6895
15	0,6323	1,4592	1,4736	0,5410	0,6457
16	3,6371	1,2239	1,9325	0,5367	0,7040
17	1,9619	6,2356	2,9077	0,4466	0,3428
18	7,1105	-	1,6977	-	0,2758
19	0,9962	0,7422	2,4089	2,5414	0,5670
20	2,1862	0,9318	10,3079	0,5242	0,3483
21	1,0362	0,8240	10,3108	0,5384	0,4768
22	0,8140	1,1608	4,9088	0,6363	0,5811
23	0,6323	-	1,4736	-	0,6457
24		0,7842		1,1603	
25		1,9634		4,3028	
26		0,8573		0,8553	
27		1,0539		0,6212	
28		0,8240		0,5384	

**Tabla I.10.** Promedios CSI para el parámetro LO evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
1	0,3696	0,4710	3,3767	1,6513	2,0582
2	0,6091	0,9312	0,8707	0,9976	23,0066
3	0,5529	0,7689	1,0680	1,0071	1,1967
4	0,4928	0,4728	0,8494	1,5929	15,9591
5	0,4258	-	35,8161	-	6,3386
6	0,5140	0,6286	0,9814	1,4621	0,4759



<b>7</b>	0,7425	0,4844	0,7835	13,1033	0,8887
<b>8</b>	0,7134	0,3301	0,7840	5,1407	0,6736
<b>9</b>	0,4972	0,4669	2,2186	1,1799	1,3207
<b>10</b>	0,4000	-	1,1940	-	0,6690
<b>11</b>	0,4270	6,1570	0,7347	1,9919	0,5647
<b>12</b>	0,9146	1,0295	0,6254	1,1970	0,7603
<b>13</b>	0,5052	-	6,2573	-	1,2218
<b>14</b>	0,3870	0,6929	4,3892	0,6669	2,0935
<b>15</b>	0,3926	0,7585	1,2888	1,3059	1,0831
<b>16</b>	0,6124	0,5763	0,5695	1,0243	5,6494
<b>17</b>	0,6849	0,6089	0,5381	1,0778	1,5939
<b>18</b>	1,9987	-	0,5701	-	1,5649
<b>19</b>	0,5564	1,1980	1,0195	1,4686	1,1814
<b>20</b>	0,7995	1,4202	1,0274	1,1287	1,4581
<b>21</b>	0,3842	0,9122	0,4427	1,1129	0,6736
<b>22</b>	0,3910	0,6687	4,4322	0,8419	0,9444
<b>23</b>	0,3926	-	1,2888	-	1,0831
<b>24</b>		0,7561		1,0084	
<b>25</b>		0,8164		0,9766	
<b>26</b>		0,7114		0,8029	
<b>27</b>		1,1374		0,8446	
<b>28</b>		0,9122		1,1129	





# CÁLCULO DE LOS PROMEDIOS CSI PARA LOS PARÁMETROS ESPECTRALES



## APÉNDICE II

Lina Andrea Arcila Armero  
Liceth Yuliana Cajas Hoyos

Director: MSc. Harold Armando Romo Romero

*Universidad del Cauca*

Facultad de Ingeniería Electrónica y de Telecomunicaciones  
Departamento de Telecomunicaciones  
Grupo Nuevas Tecnologías en Telecomunicaciones GNTT  
Popayán, Agosto de 2016



## APÉNDICE II. CÁLCULO DE LOS PROMEDIOS CSI PARA LOS PARÁMETROS ESPECTRALES.

A continuación se ilustran los promedios CSI obtenidos para los parámetros espectrales.

**Tabla II.1.** Promedios CSI para el parámetro SVD evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
1	0,4762	1,2176	15,3727	6,1733	0,6394
2	0,4315	3,1958	1,0158	1,7828	1,1141
3	0,8497	2,1516	0,3839	6,0609	1,0388
4	0,7600	1,5110	0,7811	11,1800	0,4395
5	0,5348	-	3,6225	-	0,4318
6	0,4612	1,9267	1,0219	2,2426	0,7750
7	0,7004	2,6635	0,5355	0,8564	0,8507
8	0,7281	0,8432	0,6261	1,5413	0,6021
9	0,5050	1,6435	1,5454	1,3985	0,4404
10	0,4389	-	2,4065	-	0,8019
11	0,6941	1,8362	0,8474	0,8016	1,2799
12	0,7770	1,5395	0,8534	3,5753	0,6936
13	0,7810	-	1,0548	-	0,6012
14	0,6443	1,3867	4,0193	3,5639	0,7876
15	0,5452	1,7572	0,5091	1,1756	2,2512
16	0,7432	5,2926	0,9513	1,5506	0,6419
17	0,6785	4,7998	1,6620	1,8683	0,5926
18	0,9028	-	1,0316	-	0,7873
19	0,8497	1,5111	0,3839	1,6439	1,0388
20	0,6085	1,6050	0,4583	2,3658	0,7370



<b>21</b>	0,4914	1,8445	0,6102	1,3971	0,7129
<b>22</b>	0,6295	3,4224	0,9438	4,2878	0,5969
<b>23</b>	0,5452	-	0,5091	-	2,2512
<b>24</b>		2,1516		6,0609	
<b>25</b>		2,5569		1,8755	
<b>26</b>		1,4370		4,9579	
<b>27</b>		0,8063		10,0121	
<b>28</b>		1,8445		1,3971	

**Tabla II.2.** Promedios CSI para el parámetro ENER evaluado en cada canal para los 5 pacientes. Por los autores.

<b>CANAL</b>	<b>PACIENTE 1</b>	<b>PACIENTE 2</b>	<b>PACIENTE 3</b>	<b>PACIENTE 4</b>	<b>PACIENTE 5</b>
<b>1</b>	0,6237	1,2665	5,2069	2,0398	0,7628
<b>2</b>	0,5527	32,4481	1,2688	2,1059	1,3567
<b>3</b>	0,9973	5,7020	0,4815	2,8949	5,2556
<b>4</b>	0,8416	1,7036	0,9602	5,0964	0,5886
<b>5</b>	0,6646	-	5,4095	-	0,5333
<b>6</b>	0,5964	2,0167	1,2990	1,4546	24,7517
<b>7</b>	0,7994	2,0037	0,7135	0,9500	0,9551
<b>8</b>	0,7966	0,9559	0,7967	13,8436	0,6638
<b>9</b>	0,5980	1,7603	1,3382	1,9285	0,5398
<b>10</b>	0,5490	-	2,3121	-	25,5277
<b>11</b>	0,7618	1,7946	1,1908	0,9883	6,1020
<b>12</b>	0,8640	1,6586	1,3878	2,5187	1,1715
<b>13</b>	0,9346	-	1,0823	-	0,6378
<b>14</b>	0,7775	1,3889	2,4970	2,3008	0,9263
<b>15</b>	0,7419	1,9452	0,6199	1,5671	11,2170
<b>16</b>	0,8752	7,2519	1,6658	4,1511	0,9869
<b>17</b>	0,8152	26,2058	3,5706	11,0074	2,7450
<b>18</b>	1,0859	-	1,3166	-	10,7413



<b>19</b>	0,9973	1,6188	0,4815	1,6107	5,2556
<b>20</b>	0,7464	2,8403	0,5350	2,7896	0,8495
<b>21</b>	0,6133	1,8931	0,7164	1,6700	0,8296
<b>22</b>	0,7243	3,2088	1,1700	6,3060	0,6287
<b>23</b>	0,7419	-	0,6199	-	11,2170
<b>24</b>		5,7020		2,8949	
<b>25</b>		1,8962		1,6723	
<b>26</b>		1,7156		4,9318	
<b>27</b>		0,9184		7,0943	
<b>28</b>		1,8931		1,6700	

**Tabla II.3.** Promedios CSI para el parámetro AVG evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
<b>1</b>	0,3930	0,7488	1,1957	2,7289	0,7823
<b>2</b>	0,4059	1,2187	0,5195	2,0930	52,0297
<b>3</b>	0,6622	1,0208	0,3405	1,6731	0,9780
<b>4</b>	0,6999	1,1766	0,4977	1,9759	0,4294
<b>5</b>	0,4758	-	0,9443	-	0,3551
<b>6</b>	0,4605	1,7712	0,6403	1,4344	0,5674
<b>7</b>	0,5846	2,5205	0,4046	0,9378	0,7896
<b>8</b>	0,7282	0,6219	0,4974	2,1741	0,6386
<b>9</b>	0,4468	1,2713	3,4270	2,5826	0,3875
<b>10</b>	0,4270	-	1,0003	-	0,6293
<b>11</b>	0,6519	2,1295	0,6046	0,8737	1,2412
<b>12</b>	0,8044	1,3072	0,5605	4,0662	0,7471
<b>13</b>	0,5536	-	1,8699	-	0,5743
<b>14</b>	0,5013	1,3038	1,5833	1,8965	2,5606
<b>15</b>	0,3806	1,3810	0,4374	1,5869	4,6606
<b>16</b>	0,6966	2,8975	0,5565	1,6939	0,6232



17	0,7304	4,2237	0,8219	3,4941	0,4715
18	0,8812	-	0,6890	-	0,6196
19	0,6622	1,0452	0,3405	1,2976	0,9780
20	0,5633	0,9590	0,3795	5,9055	1,1164
21	0,4611	1,0486	0,3818	4,6788	0,5047
22	0,4746	1,1197	0,6270	28,8937	1,2842
23	0,3806	-	0,4374	-	4,6606
24		1,0208		1,6731	
25		3,3297		1,3699	
26		2,0702		2,1628	
27		0,6876		2,3901	
28		1,0486		4,6788	

**Tabla II.4.** Promedios CSI para el parámetro MAX evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
1	0,5378	2,8914	5,3939	22,9471	0,8051
2	0,4670	2,9892	4,4503	2,9310	0,9471
3	0,8440	4,5039	0,4210	2,3234	1,2529
4	0,7493	1,6175	0,9073	2,4720	0,4793
5	0,6070	-	4,1731	-	0,6152
6	0,5231	1,5656	1,4781	2,1687	0,7570
7	0,7383	105,6852	0,4647	0,8292	0,9947
8	0,6843	1,3660	0,6773	1,1813	0,7681
9	0,5357	1,8504	1,8286	1,2113	0,6500
10	0,4223	-	12,3346	-	0,7047
11	0,6972	3,5555	1,0996	0,8480	1,1049
12	0,7805	2,3984	0,8633	2,9803	0,8455
13	1,0038	-	1,3274	-	0,8767
14	0,6583	2,1253	11,5281	2,2920	0,7912



<b>15</b>	0,5667	2,1272	0,6530	0,8751	2,3732
<b>16</b>	0,7773	7,1084	1,7231	1,2654	0,8567
<b>17</b>	0,8500	7,1782	2,8791	1,8420	0,5594
<b>18</b>	0,9210	-	0,7705	-	0,6926
<b>19</b>	0,8440	3,0371	0,4210	2,1920	1,2529
<b>20</b>	0,6210	4,1295	0,5381	2,4528	0,7670
<b>21</b>	0,5180	2,1375	0,7870	1,2335	1,1376
<b>22</b>	0,6660	6,2606	1,2512	4,7932	0,7202
<b>23</b>	0,5667	-	0,6530	-	2,3732
<b>24</b>		4,5039		2,3234	
<b>25</b>		1,5973		5,9267	
<b>26</b>		3,4101		7,5911	
<b>27</b>		1,1043		3,3945	
<b>28</b>		2,1375		1,2335	

**Tabla II.5.** Promedios CSI para el parámetro VAR evaluado en cada canal para los 5 pacientes. Por los autores.

<b>CANAL</b>	<b>PACIENTE 1</b>	<b>PACIENTE 2</b>	<b>PACIENTE 3</b>	<b>PACIENTE 4</b>	<b>PACIENTE 5</b>
<b>1</b>	0,6169	1,2662	5,7419	2,1514	0,7491
<b>2</b>	0,5389	68,7065	1,2323	1,9891	1,2888
<b>3</b>	0,9765	5,4867	0,4758	3,1455	4,9111
<b>4</b>	0,8390	1,7608	0,9278	5,1875	0,5839
<b>5</b>	0,6648	-	4,8308	-	0,5321
<b>6</b>	0,5901	2,1363	1,2984	1,4436	248,8370
<b>7</b>	0,7986	1,9315	0,6961	0,9629	0,9544
<b>8</b>	0,7980	0,9801	0,7942	13,2330	0,6671
<b>9</b>	0,6016	1,7890	1,3696	1,6480	0,5459
<b>10</b>	0,5465	-	2,5192	-	10,3500
<b>11</b>	0,7599	1,8310	1,1978	0,9932	7,0011
<b>12</b>	0,8423	1,6266	1,3361	2,4677	1,1718



13	0,9108	-	1,1098	-	0,6309
14	0,7637	1,4177	2,7643	2,2727	0,9024
15	0,7336	1,9657	0,6172	1,5493	12,7763
16	0,8648	6,0965	1,6762	3,1287	0,9852
17	0,7988	28,4207	3,4696	7,0280	2,3233
18	1,0792	-	1,2646	-	11,9971
19	0,9765	1,6101	0,4758	1,6084	4,9111
20	0,7360	3,0055	0,5276	2,5951	0,8465
21	0,6119	1,8728	0,7074	1,6245	0,8177
22	0,7258	3,2183	1,0903	6,1313	0,6377
23	0,7336	-	0,6172	-	12,7763
24		5,4867		3,1455	
25		1,9198		1,6590	
26		1,7295		5,9138	
27		0,9116		9,0513	
28		1,8728		1,6245	

**Tabla II.6.** Promedios CSI para el parámetro ApEn evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
1	2,9644	56,9686	27,7228	5,0336	1,7141
2	4,8228	14,3181	51,4508	5,5012	2,4800
3	5,5291	4,4353	1,2131	7,2814	4,0735
4	2,5794	208,1269	1,2073	1,8743	3,1645
5	2,0227	-	16,6638	-	6,5532
6	5,8587	5,2555	7,9605	47,9902	1,3107
7	3,7494	3,0653	5,0897	19,0602	2,2418
8	2,4703	4,0985	3,3826	28,4051	7,3512
9	27,4292	20,1957	5,7223	2,3835	4,6366
10	6,2256	-	4,6388	-	1,7100



11	7,1322	15,8171	1,5242	5,4887	2,0850
12	17,0070	7,8241	2,8621	5,0187	1,3423
13	6,8812	-	4,9154	-	2,3996
14	2,4896	2,6717	1,9528	6,0338	1,5612
15	5,7281	18,5863	1,3262	3,5900	3,9307
16	4,3515	16,8560	3,8624	3,9200	3,1522
17	3,7595 $e^3$	8,8313	4,7795	3,5682	20,8094
18	12,7087	-	41,1663	-	1,6789
19	5,5291	1,9374	1,2131	68,6148	4,0735
20	4,7129	7,9801	2,3446	48,5910	1,5583
21	1,4755	6,3777	1,6453	3,3020	1,5948
22	2,9295	8,8403	1,3927	3,4254	1,3079
23	5,7281	-	1,3262	-	3,9307
24		4,4353		7,2814	
25		1,2467		11,7669	
26		2,6517		15,0865	
27		2,6291		30,2058	
28		6,3777		3,3020	

**Tabla II.7.** Promedios CSI para el parámetro Entropía muestral evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
1	7,4831	5,6661	13,4884	8,7198	2,8184
2	173,2046	3,5155	2,5471	4,8563	4,7640
3	22,3368	4,3699	2,6885	3,3423	2,6740
4	12,3187	10,3151	6,8480	5,1603	4,5785
5	60,7279	-	4,9729	-	1,9735
6	10,4991	6,1148	3,6110	45,4162	12,8070
7	7,1652	3,0031	7,3132	17,8935	4,0053
8	9,6722	12,2699	7,3127	5,8606	2,3916



9	6,9734	3,1700	9,9735	1,9220	2,9937
10	15,7671	-	5,8369	-	4,9425
11	48,7584	63,8945	8,0570	6,5235	147,5517
12	7,6588	7,6754	3,6819	53,9025	3,5268
13	8,9092	-	197,3202	-	2,3184
14	5,9177	2,5596	34,4214	8,7410	3,4700
15	8,7533	4,6400	2,3623	8,9102	3,3163
16	8,1358	9,2828	3,2043	29,3213	7,5782
17	6,2423	28,5250	1,9941	2,0375	5,8086
18	14,0208	-	6,4824	-	2,4336
19	22,3368	3,3159	2,6885	6,5412	2,6740
20	5,3861	6,5608	3,2336	13,9882	4,4468
21	8,3257	21,4319	19,7053	49,6329	2,4164
22	20,5636	2,5417	2,4330	4,0268	4,4001
23	8,7533	-	2,3623	-	3,3163
24		4,3699		3,3423	
25		4,1058		95,5510	
26		1,7158		9,7857	
27		8,5330		3,7077	
28		21,4319		49,6329	

**Tabla II.8.** Promedios CSI para el parámetro Entropía espectral evaluado en cada canal para los 5 pacientes. Por los autores.

CANAL	PACIENTE 1	PACIENTE 2	PACIENTE 3	PACIENTE 4	PACIENTE 5
1	2,3130	3,9323	3,3184	7,3202	2,6032
2	2,7759	2,4307	1,8641	3,7934	3,4620
3	2,8429	1,9815	0,9050	1,4515	2,0118
4	4,5003	2,9885	1,0412	1,2675	4,4412
5	3,1339	-	73,7286	-	1,2278
6	3,3757	1,8666	1,3798	17,4691	5,8371



<b>7</b>	1,5943	2,0036	1,0667	2,2855	1,2200
<b>8</b>	1,9995	29,3877	0,9221	3,6281	0,9966
<b>9</b>	4,0745	5,5255	3,5660	1,5623	1,5081
<b>10</b>	3,7351	-	1,4764	-	1,3538
<b>11</b>	8,6243	1,6793	1,0169	16,0629	2,7349
<b>12</b>	9,4617	3,0884	5,8783	4,4583	2,7715
<b>13</b>	1,4741	-	4,0756	-	1,0073
<b>14</b>	4,2468	1,6080	2,5585	6,9730	1,9087
<b>15</b>	2,5006	2,2869	0,9300	4,0733	2,5325
<b>16</b>	5,6001	3,0895	1,5130	97,0897	3,9879
<b>17</b>	4,4569	4,3652	2,5264	1,2239	1,5021
<b>18</b>	2,9469	-	1,2613	-	0,8999
<b>19</b>	2,8429	3,1568	0,9052	2,2803	2,0118
<b>20</b>	4,3066	2,1348	1,1449	3,1810	2,6322
<b>21</b>	6,4830	1,5669	5,7766	1,3972	1,2366
<b>22</b>	2,3997	1,8479	0,9120	1,5228	1,3594
<b>23</b>	2,5006	-	0,9300	-	2,5325
<b>24</b>		1,9815		1,4515	
<b>25</b>		14,8942		2,3167	
<b>26</b>		29,7643		3,4383	
<b>27</b>		1,5684		1,2400	
<b>28</b>		1,5669		1,3972	

