

**ANÁLISIS TIEMPO-FRECUENCIA DE SEÑALES DE ELECTROMIOGRAFÍA  
PARA EL DIAGNÓSTICO DE LESIONES DE PLEXO BRAQUIAL**

Carlos Julián Gallego Duque

**INSTITUTO TECNOLÓGICO METROPOLITANO  
FACULTAD DE INGENIERÍAS  
MAESTRÍA EN AUTOMATIZACIÓN Y CONTROL INDUSTRIAL  
MEDELLÍN, 2015**

**ANÁLISIS TIEMPO-FRECUENCIA DE SEÑALES DE ELECTROMIOGRAFÍA  
PARA EL DIAGNÓSTICO DE LESIONES DE PLEXO BRAQUIAL**

Carlos Julián Gallego Duque

Trabajo de grado para optar al título de Magister en Automatización y Control  
Industrial

**Directores**

**Director:** Edilson Delgado Trejos, Dr. Ing.

**Co Director:** Leonardo Duque Muñoz, M. Ing.

**INSTITUTO TECNOLÓGICO METROPOLITANO**

**FACULTAD DE INGENIERÍAS**

**MAESTRÍA EN AUTOMATIZACIÓN Y CONTROL INDUSTRIAL**

**MEDELLÍN, 2015**

**TIME FREQUENCY ANALYSIS ON ELECTROMYOGRAPHY SIGNALS  
ORIENTED TOWARD THE BRACHIAL PLEXUS INJURY DIAGNOSIS**

Carlos Julián Gallego Duque

A thesis submitted to the graduate program “Masters in Industrial Control and Automation” in partial fulfillment of the requirements for the Master's degree

**Supervisors**

Edilson Delgado Trejos, Dr. Eng.

Leonardo Duque Muñoz, M. Eng.

**INSTITUTO TECNOLÓGICO METROPOLITANO**

**FACULTY OF ENGINEERING**

**MASTERS IN INDUSTRIAL CONTROL AND AUTOMATION**

**MEDELLÍN, 2015**

**Nota de aceptación**

---

---

---

---

---

---

---

Firma

Nombre

Presidente del jurado

---

Firma

Nombre

Jurado

---

Firma

Nombre

Jurado

Medellín, Abril de 2015

## DEDICATORIA

Esta tesis se la dedico a DIOS por darme la vida, a mi esposa Alejandra que me ha apoyado incondicionalmente, a mi hija Juliana que a pesar de su temprana edad ha sido la motivación para obtener este gran logro; a mis padres Piedad y Gabriel que gracias a ellos, hoy puedo aportarle algo positivo a la sociedad.

En la misma medida hago extensiva esta dedicatoria a mis hermanos Gabriel Jaime y Jorge Mario por su acompañamiento, a mis abuelos por sus consejos y buen ejemplo. Por último y no menos importante, a mí amigo Carlos Alberto y al médico José Fernando quienes me han acompañado e impulsado en la consecución de este sueño.

## CONTENIDO

INTRODUCCIÓN .....	1
1. Estado del arte .....	5
1.1 Señales electromiográficas cuantitativas (QEMG) .....	5
1.2 Transformadas tiempo-frecuencia.....	7
1.3 Técnicas de extracción de características .....	9
1.4 Reducción de características .....	11
1.5 Clasificación .....	13
1.6 Influencia de la Transformada Wavelet en la descomposición de señales EMG .....	19
1.7 Recomendaciones .....	22
2. Preliminares teóricos.....	23
2.1 Plexo braquial .....	23
2.1.1 Lesión de plexo braquial .....	24
2.2 Electromiografía clínica.....	27
2.3 Transformada Wavelet (WT).....	28
2.3.1 Transformada Wavelet Continua (CWT).....	29
2.3.2 Transformada Wavelet Discreta (DWT).....	29
2.4 Análisis de relevancia .....	30
2.4.1 Análisis de Componentes Principales (PCA).....	31
2.4.2 Entropía Difusa (ED) .....	32
2.4.3 Variabilidad Estocástica (VE). .....	33
2.5 Clasificador de K vecinos más cercanos (K-nn).....	36
3. Marco experimental.....	37
3.1 Base de datos .....	37
3.2 Metodología propuesta .....	40
3.2.1 Señales EMG .....	40
3.2.2 Descomposición de las señales EMG por medio de la DWT y extracción de características.....	40
3.2.3 Análisis de relevancia .....	44
3.2.4 Clasificación .....	44
4. Resultados y discusión .....	47
4.1 Prueba con normalización.....	47
4.2 Prueba con combinación de características estadísticas y de energía normalizadas .....	50

4.3	Prueba bi-clase con combinación de características estadísticas y de energía .....	53
4.4	Prueba con los valores absolutos de los coeficientes Wavelet. ....	59
4.5	Ajuste del clasificador.....	62
4.6	Selección de características.....	63
4.6.1	Análisis de Componentes Principales.....	63
4.6.2	Selección con Entropía Difusa.....	64
4.6.3	Selección con Variabilidad Estocástica .....	64
4.6.4	Comparación de los resultados obtenidos con los algoritmos de VE y ED	65
4.7	Ajuste de la Wavelet madre .....	66
4.8	Mejor esquema de clasificación .....	67
4.9	Discusiones.....	69
	CONCLUSIONES Y TRABAJO FUTURO .....	73
	Referencias.....	75

## LISTA DE TABLAS

Tabla 1. Matriz de confusión	46
Tabla 2. Clasificación sin normalizar $\Omega$ .....	48
Tabla 3. Clasificación con normalización estadística $\Omega$ .....	49
Tabla 4. Clasificación con normalización geométrica de $\Omega$ .....	49
Tabla 5. Clasificación con todas las características normalizadas.....	51
Tabla 6. Clasificación con características estadísticas normalizadas. ....	51
Tabla 7. Clasificación con las características de energía normalizadas.....	52
Tabla 8. Prueba ALS y MIO con todas las características normalizadas. ....	53
Tabla 9. Prueba ALS y MIO con características estadísticas normalizadas.....	54
Tabla 10. Prueba ALS y MIO con características de energía normalizadas. ....	54
Tabla 11. Prueba ALS y NOR con todas las características normalizadas. ....	55
Tabla 12. Prueba ALS y NOR con características estadísticas normalizadas. ....	55
Tabla 13. Prueba ALS y NOR con características de energía normalizadas .....	56
Tabla 14. Prueba MIO y NOR con todas las características normalizadas. ....	57
Tabla 15. Prueba MIO y NOR con características estadísticas normalizadas. ....	57
Tabla 16. Prueba MIO y NOR con características de energía normalizadas .....	57
Tabla 17. Clasificación con valores absolutos de los coeficientes sin normalizar .... .....	59
Tabla 18. Clasificación con valores absolutos de los coeficientes normalizados .....	59
.....	59
Tabla 19. Características idénticas obtenidas con ED y VE.....	65
Tabla 20. Mejores índices de clasificación. ....	67

Tabla 21. Matriz de confusión para mejores índices de clasificación. ....	71
Tabla 22. Comparación de la metodología propuesta frente a otros estudios. ....	71

## LISTA DE FIGURAS

Figura 1. Esquema de plexo braquial.....	23
Figura 2. Algoritmo de Clasificación de las lesiones de plexo braquial.....	24
Figura 3. Señal EMG.....	27
Figura 4. Señal EMG de paciente Normal.....	37
Figura 5. Señal EMG de paciente Miopático .....	37
Figura 6. Señal EMG de paciente con Esclerosis Lateral Amiotrófica. ....	38
Figura 7. Esquema general del procedimiento.....	40
Figura 8. Árbol DW8 con seis niveles de descomposición .....	41
Figura 9. Prueba de clasificación con distintas normalizaciones.....	50
Figura 10. Error prueba de clasificación con combinación de características .....	52
Figura 11. Error prueba bi-clase ALS y MIO con combinación de características normalizadas.....	54
Figura 12. Error prueba bi-clase ALS y NOR con combinación de características normalizadas.....	56
Figura 13. Error prueba bi-clase MIO y NOR con combinación de características normalizadas.....	58
Figura 14. Error clasificación con los valores absolutos.....	60
Figura 15. Error mejores resultados de las pruebas.....	61
Figura 16. Valor óptimo de ' $k$ '.....	62
Figura 17. Análisis de Componentes Principales. ....	63
Figura 18. Selección de características más relevantes con ED.....	64
Figura 19. Selección de características más relevantes con VE .....	64
Figura 20. Ajuste de la Wavelet madre .....	66

Figura 21. Comparación de Acc (%), pruebas 3.4 y 3.8.....	68
---	----

## AGRADECIMIENTOS

Quiero agradecer a Dios y a todas las personas que han contribuido de alguna forma para el desarrollo de esta investigación. Gracias al Dr. Ing Edilson Delgado Trejos, quien asesoró esta tesis. Gracias al M. Ing Leonardo Duque Muñoz codirector de la misma, ya que hicieron posible la culminación del proyecto por medio de su acompañamiento, explicación y recomendaciones.

Por otra parte, doy gracias a mi familia, amigos y muy especialmente a mi esposa y madre que sin su apoyo no hubiese sido posible culminar este trabajo realizado con dedicación, paciencia y esmero. Espero recompensar todos los malos ratos y solo me resta decir **Gracias**.

## RESUMEN

En la presente investigación se propone una metodología basada en el análisis tiempo-frecuencia para el diagnóstico de lesiones de plexo braquial. La cual tendrá el potencial para servir como soporte al diagnóstico de lesiones como Esclerosis Lateral Amiotrófica (ALS) y Miopatía (MIO) a fin de que se pueda definir un tratamiento con mayor efectividad. En esta tesis se utilizó una base de datos suministrada por la Facultad de Ciencias de la Salud de la Universidad de Copenhague, conformada por 395 registros en total, los cuales fueron separados en 3 clases así: 270 de control, 82 de pacientes con MIO y 43 de pacientes con ALS. La descomposición de la señal de electromiografía se realizó por medio de la Transformada Wavelet Discreta utilizando la familia Daubechies 8 con seis niveles de descomposición y, posteriormente, se estimaron características de energía e información estadística para cada nivel de descomposición. Adicionalmente, se realizó un análisis para determinar las características más relevantes, mediante Análisis de Relevancia estocástico y entropía difusa. Finalmente se validó la metodología mediante un procedimiento de validación cruzada con 10-folds. Para la clasificación se utilizó un clasificador de K vecinos más cercanos (K-nn), obteniendo una máxima tasa de acierto del  $93.91 \pm 0.99\%$ . Los resultados muestran que este método constituye una alternativa para el diagnóstico de lesiones de plexo braquial.

Palabras Claves: Señales EMG, Esclerosis Lateral Amiotrófica, Miopatía, Transformada Wavelet Discreta, Análisis de Relevancia, Entropía Difusa, Variabilidad Estocástica, Clasificador K-nn.

## ABSTRACT

This research is intended to propose a methodology based on time-frequency analysis for diagnosing brachial plexus injuries. The methodology will potentially serve as support for diagnosing lesions such as Amyotrophic Lateral Sclerosis (ALS) and Myopathy (MIO) in order to define a more effective treatment. The used database were provided by the Faculty of Health Sciences, University of Copenhagen, comprising 395 records in total, which were separated into 3 classes and 270 controls, 82 patients with MIO and 43 patients with ALS. Decomposition of the electromyography signal was conducted with the Discrete Wavelet Transform by using Daubechies 8 family with six decomposition levels and then energy characteristics and statistical information for each decomposition level were estimated. Additionally, an analysis of relevance was used for determining the most relevant characteristics. Finally, the methodology was validated with a cross validation procedure. A k-Nearest Neighbors classifier was used and a maximum accuracy rate of  $93.91 \pm 0.99\%$  was obtained. Results show that this methodology constitutes an alternative for diagnosing brachial plexus injuries.

**Key words:** EMG signals; Amyotrophic Lateral Sclerosis; myopathy; Discrete Wavelet Transform; analysis of relevance; fuzzy entropy; stochastic variation; k-NN classifier.

## INTRODUCCIÓN

Las enfermedades neurodegenerativas al igual que las neuromusculares son motivo de estudio por médicos y científicos, debido a que afectan los nervios que controlan los músculos voluntarios, como es el caso de los brazos y las piernas. Las células nerviosas, también llamadas neuronas, envían mensajes que controlan esos músculos, cuando las neuronas se enferman o se mueren, la comunicación entre el sistema nervioso y los músculos se interrumpe, debilitándose y consumiéndose. La debilidad, puede conducir a espasmos musculares, calambres, dolores, problemas articulares y del movimiento.

La Esclerosis Lateral Amiotrófica (Amyotrophic Lateral Sclerosis-ALS) o también conocida como la enfermedad de Lou Gehrig, es una enfermedad neurodegenerativa que sólo en Colombia causa la muerte a veinte personas al año. La expectativa de vida de un paciente con esta enfermedad se encuentra entre 1 y 3 años (Arroyave, 2014). En la actualidad la ALS carece de una terapia curativa, su manejo se basa en el tratamiento paliativo (atenúa los efectos) y el control de los síntomas. La ALS se define como una enfermedad crónica y degenerativa, generalmente, de origen desconocido que se caracteriza por la muerte progresiva de las motoneuronas centrales y periféricas, produciendo debilidad y atrofia muscular (Ravits, 2014).

Por otra parte, las miopatías que corresponden a enfermedades neuromusculares, generalmente se presentan por trastornos de conducción del impulso nervioso como las lesiones de plexo braquial. Esta lesión tiene una mayor incidencia en accidentes de tránsito, los cuales para el 2020 podrían convertirse en la tercera causa de morbilidad en el mundo según la Organización Mundial de la Salud, OMS (2004). Del total de lesionados a nivel nacional, el 34.6% presentaron traumatismo de extremidades (Forero y Valvuela, 2009),

donde el 14.9% presentaron lesión de miembros superiores (Gallego, 2009). La lesión de plexo braquial se produce en el 14% de las luxaciones de hombro, siendo el nervio axilar y musculo-cutáneo los que más frecuentemente se lesionan según Swiontkwski (2005). Un traumatismo de plexo braquial es una lesión de uno o más nervios localizados entre el cuello y la espalda, y es ocasionada por una separación o estiramiento del plexo braquial. La forma más confiable de diagnosticar este tipo de lesión, es mediante un examen clínico basado en el registro y análisis de la actividad bioeléctrica del músculo conocido como electromiografía (EMG). La electromiografía se orienta hacia el análisis de las enfermedades neuromusculares y proporciona una fuente de información para el diagnóstico de diferentes trastornos.

Hacer una aproximación cuantitativa de dicha prueba y estandarizarla en una base de datos, permitiría establecer un diagnóstico de funcionalidad y disminuiría la subjetividad en la interpretación de los resultados de dicha prueba; por esta razón, desarrollar una metodología para la descomposición y clasificación de señales EMG con análisis tiempo-frecuencia, posibilitaría encontrar la dinámica temporal y espectral de la señal, además de apoyar el diagnóstico de lesiones de plexo braquial en traumatismo cerrado.

## **Hipótesis**

La implementación del análisis cuantitativo de señales EMG con análisis tiempo-frecuencia, en el cual se pueda encontrar la dinámica temporal y frecuencial de la señal, ayudará a la clasificación automática de lesiones de plexo braquial como ALS y miopatía.

## **Objetivo general**

Proponer una metodología de clasificación de señales de electromiografía (EMG) mediante el análisis tiempo-frecuencia, orientada al diagnóstico de lesiones de plexo braquial en traumatismo cerrado.

## **Objetivos específicos**

- Caracterizar las señales de EMG mediante técnicas de descomposición tiempo-frecuencia.
- Proponer un análisis de relevancia sobre el sistema de caracterización que posibilite reducir el espacio de alta dimensión, y brinde información sobre las características más importantes para la clasificación de señales de EMG.
- Validar la metodología diseñada en señales de EMG con lesiones del plexo braquial utilizando una estrategia de validación cruzada con señales previamente etiquetadas por un experto.

## **Organización del manuscrito**

Este manuscrito está organizado en cuatro capítulos: el primer capítulo constituye el estado del arte, donde se muestran los estudios que se han realizado en torno a la metodología que se propone para el objeto de esta investigación. En los capítulos dos y tres se presentan los preliminares teóricos y el marco experimental, respectivamente. Donde se aborda la estructura técnico-científica que da la frontera conceptual a la investigación en forma de un sistema coordinado y coherente. En el cuarto capítulo se exponen los resultados y discusión, a fin de mostrar las diferentes pruebas realizadas, explicando los hallazgos obtenidos para la posterior discusión de cada uno de ellos. También, en éste último capítulo se presentan las conclusiones, donde se determinan las fortalezas, debilidades, restricciones, limitaciones y rangos de operación de la metodología propuesta de manera concreta. En este capítulo también se incluyen los trabajos futuros.

## **Aporte de la tesis**

En esta tesis, se desarrolló una metodología de análisis de señales no estacionarias (señales biológicas como EMG), basada en la transformada Wavelet y caracterización mediante funciones estadísticas y de energía. Se realizó un análisis de relevancia mediante PCA, entropía difusa y análisis de relevancia estocástico, logrando un diagnóstico de lesiones de plexo braquial mediante un clasificador de fácil implementación.

# 1. Estado del arte

## 1.1 Señales electromiográficas cuantitativas (QEMG)

La EMG es una técnica para evaluar y registrar la actividad eléctrica producida por los músculos esqueléticos, durante las actividades musculares voluntarias e involuntarias (Mills, 2005). Estas señales pueden ser analizadas para detectar anomalías médicas en los músculos aunque se debe tener en cuenta, su naturaleza no estacionaria y entorno ruidoso. En los últimos años Krarup (2011), Johnsona (2012), Shanette (2014), Ioanna (2014) y Biancolillo (2015), entre otros, han investigado la manera de proporcionar un medio preciso y computacionalmente eficiente de clasificación cuantitativo de las señales de electromiografía (Quantitative Electromyography - QEMG); las cuales aportan una fuente importante de información para el diagnóstico de los trastornos neuromusculares.

Se han utilizado distintos métodos para caracterizar las unidades motoras individuales de un músculo a través del análisis de Unidades Motoras (UMs) aisladas para ayudar a determinar la presencia o ausencia de enfermedad neuromuscular. Pino, Stashuk, Boe y Doherty (2009), presentan un trabajo basado en señales que fueron adquiridas a partir de un músculo y se almacenaron en una base de datos conformada por tres clases: miopático, normal y neuropático. Se extrajeron características basadas en los patrones de valores del potencial de unidad motora. La clasificación se realizó por medio de un clasificador Bayesiano con el que se encontró una precisión del 84.4% en contra de un 51.9% obtenido por los métodos basados en valores atípicos.

Por otra parte Kaur, Shatru y Kumar (2010), encontraron que las formas y tasas de disparo de los potenciales de acción de unidad motora (PAUMs) en una señal de EMG proporcionaron una importante fuente de información para el diagnóstico de los trastornos neuromusculares. La base de datos utilizada para esta

investigación se obtuvo del departamento de Ciencias de la Computación de la Universidad de Chipre. Todas las señales EMG fueron adquiridas del músculo bíceps braquial con un 30% de contracción voluntaria. La muestra estaba conformada por 12 pacientes agrupados en tres clases, 3 sujetos normales (NOR), 5 pacientes con miopatía (MIO) y 4 pacientes con enfermedad de la motoneurona (MND). Para las señales adquiridas por Kaur et al. (2010), el registro se hizo durante 5 segundos utilizando un electrodo de aguja concéntrica estándar, un filtro con banda pasante entre 3KHZ y 10 KHz, una frecuencia de muestreo de 20 KHz con una resolución de 12 bits y por último se aplicó un filtro paso bajo a una frecuencia de 8 KHz a las señales EMG. Con el fin de identificar los PAUMs que componían las señales EMG, fueron segmentadas con la técnica de umbral, donde se extrajeron características como el valor promedio de las clases (los valores límite de cada grupo se eligieron Heurísticamente) y para clasificarlas se utilizó un clasificador binario integrado basado en máquinas de soporte vectorial (Support Vector Machines-SVM), logrando determinar el grado de participación de la enfermedad (MIO o MND) debido a que cada unidad motora en un conjunto UMs de la muestra de un músculo, fue objetivamente caracterizadas con un valor numérico con una precisión del 100%. Por consiguiente, la caracterización usando solo una UM, fue un primer paso hacia una caracterización neuromuscular cuantitativa.

Un primer intento de análisis de las señales EMG en forma cuantitativa fue un software llamado PLEXUS (Daalen, Stassen, Thomeer y Slooff, 1993). Este se desarrolló con el fin de proporcionar recomendaciones para el diagnóstico y tratamiento de lesiones del plexo, basado en un mecanismo de razonamiento llamado Delfi2+. Este software se destinó para neurólogos, neurocirujanos y cirujanos ortopédicos que no tienen experiencia en lesiones de plexo braquial. PLEXUS suponía la ubicación y la gravedad de la lesión plexo-braquial, además sugería si el paciente debería ser referido a un centro especializado para la cirugía de los nervios; los resultados arrojados por el software se validaron por cuatro expertos en plexo braquial pero éste, no tuvo buena acogida entre los clínicos (Daalen et al. 1993).

El software PLEXUS fue un primer acercamiento para el análisis cuantitativo de lesiones de electromiografías enfocadas a lesiones de plexo braquial, aunque se ha venido estudiando distintos métodos cuantitativos para la caracterización de señales EMG como el descrito por Pino et al. (2010), donde se utilizaron métodos probabilísticos para la caracterización de neuropatías en distintos músculos como el bíceps y los músculos interóseos, logrando un porcentaje de clasificación del 94.6% utilizando la regla de Bayes.

Es de mencionar que para las señales biomédicas como son, las señales de Electrocardiografía (ECG), Electromiografía (EMG), Electroencefalografía (EEG), Electroneurografía (ENG), fonocardiografía (FCG) y señales de voz entre otras, las transformadas tiempo-frecuencia proporcionan un método adecuado para su análisis, debido a su naturaleza no estacionaria (Quiceno, Hernández y Travieso, 2009).

## **1.2 Transformadas tiempo-frecuencia**

Estas transformadas se basan en el principio de incertidumbre de Heisenberg (1927) *“dos características de una partícula no pueden ser medidas exactamente al mismo tiempo. Cualquier intento de medir ambos resultados conlleva a imprecisiones”*, el cual aparece en todas las transformadas tiempo-frecuencia que se utilicen. Existe una gran cantidad de métodos para hallar representaciones espectrales y distribuciones tiempo-frecuencia, las cuales pueden clasificarse en dos grandes grupos: métodos paramétricos y no paramétricos. Los métodos paramétricos requieren un modelo previo de la señal (Quiceno, 2009). En señales biomédicas, dados los problemas inherentes de este tipo de señales, referidas a su entorno ruidoso, componentes no estacionarios, el uso de métodos clásicos derivados del análisis de Fourier no es efectivo según Figliola y Serrano (1997), por lo que es más conveniente usar una transformada que tenga buena

resolución temporal a altas frecuencias, y a la vez, buena resolución en frecuencia con registros largos. Por este motivo, se centró la búsqueda de información en el uso de la transformada Wavelet (Wavelet Transform-WT) para el procesamiento de las señales FCG, la cual logra que su resolución varíe en el plano tiempo-escala, siendo capaz de adaptarse a las características de cada señal como en el experimento descrito por Martínez y Ruiz (2004), cuya investigación se centró en el uso de la WT y el paquete de la transformada Wavelet (Wavelet Packet Transform-WPT) para la compresión de las señales FCG. La WT y WPT se aplicaron a 52 registros almacenados en formato WAV (16 bits de resolución y 8000 Hz de frecuencia de muestreo). En esta base de datos se incluyeron registros de sonidos normales y de diversas patologías valvulares (tercer ruido, cuarto ruido, clics, soplos sistólicos, diastólicos y continuos, entre otros.). El algoritmo de compresión constó de cuatro etapas: la primera de ellas fue la descomposición de las señales FCG mediante la WT y WPT, la segunda etapa consistió en la aplicación de un umbral a los coeficientes Wavelet, la tercera fue la compresión del vector de los coeficientes wavelet, empleando eliminación de ceros y cuantización lineal, y la cuarta etapa consistió en la compresión del mapa de posición, empleando eliminación de ceros y las codificaciones de Run Length Encoding (RLE) y Huffman. Al aplicar este algoritmo, se encontró una tasa de compresión del 99.9% con la Daubechies 8 frente a una tasa de 20.86% con el método de compresión de audio de código abierto (OGG Vorbis), demostrando ser más eficiente la transformada Wavelet específicamente para el rango de frecuencias de los FCG. Por otra parte Poza, Abásolo, Gómez, Sánchez y López (2004), utilizaron la transformada Wavelet discreta (Discrete Wavelet Transform-DWT) para analizar señales EEG y determinar la enfermedad de Alzheimer. Las señales EEG procedían de la actividad cerebral espontánea, captada por 19 electrodos, los registros se efectuaron en el Hospital Universitario de Valladolid, en una sala aislada, con los sujetos sentados, despiertos, quietos, relajados y con los ojos cerrados para minimizar la presencia de artefactos oculares. La base de datos estaba conformada por 11 individuos de control (7 hombres y 4 mujeres) y 11 pacientes

con Alzheimer (5 hombres y 6 mujeres). La descomposición de las señales se realizó mediante la DWT con la familia Daubechies de orden 4 (DB4) y 8 niveles de descomposición, calculando la potencia relativa (PR) Wavelet, y se efectuó un análisis de significación el cual consistió en: promediar los valores de la PR para cada clase en todos los canales. Con este análisis, se encontró el umbral de precisión calculando el área bajo la curva de las características de operación de receptor (Receiver Operating Characteristic-ROC). Los índices encontrados fueron: sensibilidad (Sen (%)) del 87.5%, especificidad (Sp (%)) del 100% y porcentaje de acierto (Acc (%)) del 93.75%. Crespo, Sánchez, Hurtado y Baz (2006), bajo condiciones similares a la investigación anterior, utilizaron de nuevo la WT como apoyo al diagnóstico de la enfermedad de Alzheimer. En esta oportunidad, se utilizó la Wavelet madre con un filtro DB4 con 4 y 5 niveles de descomposición donde se encontró un comportamiento más rítmico y ordenado del EEG.

Debido a la estructura no estacionaria de las señales biomédicas, se debe realizar un análisis simultáneo de la señal en el dominio del tiempo y la frecuencia con el fin de obtener una correcta extracción de características y clasificación de las señales (Delgado, Jaramillo, Quiceno y Manrique, 2007).

### **1.3 Técnicas de extracción de características**

La extracción de características es un proceso por el cual los atributos de las señales son calculados y recolectados en forma de vector. El objetivo de la extracción de características es crear una representación significativa de la señal EMG original, esto con el fin de maximizar el éxito potencial de una posterior fase de clasificación y a su vez el rendimiento global del sistema (Phinyomark, Phukpattaranont y Limsakul, 2012). El éxito de la fase de extracción de características depende básicamente de la calidad de las señales medidas y para lograr esto, el conjunto de características debe ser elegido de tal manera que se

maximice la separación entre clases y minimice la distancia entre patrones de una misma clase.

Se ha propuesto múltiples métodos y técnicas de extracción de características, como es el caso de la transformada de Fourier en tiempo corto (Short-time Fourier Transform-STFT), la Transformada Wavelet Continua (Continuous Wavelet Transform-CWT) y la DWT. Con ellas se puede obtener información de la señal en el dominio del tiempo y la frecuencia según Raez (2006), Sjiang (2003), Zecca, Micera, Carrozza y Dario (2002). Dichas técnicas son descritas por Doulah, Fattah, Zhu y Ahmad (2014), donde se encontró que no todos los PAUMs obtenidos a través de la descomposición Wavelet son capaces de representar de forma única una clase. Por lo tanto, se plantea como solución para este problema, hallar un potencial de acción de unidad motora dominante basado en el criterio de energía, es decir, en lugar de todos los PAUMs, solo el PAUM dominante se utiliza para la clasificación, la cual se realizó utilizando un clasificador de  $k$  vecinos más cercanos K-nn obteniendo un rendimiento satisfactorio en términos de Sp (%), sen (%) y Acc (%) global de clasificación. Algunas de las características temporales utilizadas para la clasificación de señales según Subasi (2012), Yücel y Mehmet (2002) Betancourt, Giraldo y Franco (2004) y Hargrove, Englehart y Hudgins (2007), son:

- Valor medio absoluto.
- Valor medio absoluto de pendientes.
- Cruces por cero.
- Cambios de signo de pendiente.
- Longitud de la Forma de Onda.
- STFT.
- CWT.
- DWT (Adeli, Zhou y Damehr 2006).
- WPT.

Una vez se tiene una distribución tiempo-frecuencia que represente adecuadamente el comportamiento espectral de la señal a lo largo del tiempo, se debe solucionar el problema relacionado con la gran cantidad de datos que se obtiene a partir de la distribución tiempo-frecuencia.

## 1.4 Reducción de características

La información obtenida de la descomposición tiempo-frecuencia puede ser redundante en el espacio de representación. Debido a esto, surge la necesidad de reducir la dimensionalidad del espacio de entrada, buscando por un lado la optimización del tiempo de cálculo, evitar la redundancia al tratar con características altamente correlacionadas, y por otro lado eliminar los datos que no presentan información significativa. La reducción de características también contribuye a la disminución de la complejidad del proceso de clasificación y el incremento de su desempeño. Entre los métodos de reducción de dimensionalidad, se encuentran los de reducción por selección de características y los de reducción por proyección de características (Hudgins, Parker y Robert, 1993).

- **Proyección o extracción de características:** Existen diferentes de métodos como los Heurísticos, algoritmos genéticos, regresión de mínimos cuadrados parciales (Partial Least Squares-PLS) (Biancolillo, 2014), análisis de componentes principales (Principal Component Analysis -PCA), entre otros. Estos consisten en determinar la mejor combinación de las características iniciales, para así formar un conjunto de características de menor dimensionalidad. Estas técnicas son útiles y efectivas en reconocimiento de patrones, pues reducen la complejidad de las características del espacio de representación y además reducen la dependencia lineal entre los datos. Uno de los métodos utilizados es el PCA, el cual consiste en una proyección lineal del conjunto original de

características en un conjunto reducido de características no correlacionadas, a la vez que se minimiza el error cuadrático medio entre los dos conjuntos según Graupe (1982), Englehart (2001) y Hudgins (2001). PCA es un método efectivo en aplicaciones de reconocimiento de patrones y utilizado con señales EMG como muestran Englehart, Hudgin y Parker (2001), Hu, Wang y Ren (2005), Yücel (2002), Zhang (2002) y Zhang (2004). También existen otros métodos como el PCA probabilístico descrito por Michael y Christopher (1999), Tipping y Bishop (2006), escalamiento multidimensional por Pena (2002), análisis factorial por Peña (2002) y Rencher (2005) y búsqueda de proyección por Fodor (2002).

- **Selección de características:** Consiste en reducir el número de características de entrada, encontrando el mejor subconjunto que represente la señal original (Delgado, 2008). La selección de características está formada por un criterio que puede ser establecido ya sea, para juzgar si un subconjunto de características es mejor que otro o, por un procedimiento sistemático que permita encontrar el subconjunto de características. Un ejemplo de estos criterios puede ser medir la separabilidad de clases por Liu (2014), a fin de conformar el mejor subconjunto de características a partir de la selección de las mejores características del conjunto original. Existen diferentes técnicas de selección de características como la búsqueda secuencial flotante (Nakariyakul y Casasent, 2009), búsqueda secuencial hacia adelante y hacia atrás (Ruiz, Riquelme y Ruiz, 2005), árboles de decisión (Wang, Liu, Pedrycz y Zhang, 2015), entre otras. Para el caso de las Heurísticas donde no se analizan todos los subconjuntos posibles, pueden convertirse en inconvenientes dada que una porción de la información contenida en el conjunto original se pierde por el hecho de descartar algunas de sus características.

## 1.5 Clasificación

La fase de clasificación es un componente importante de los sistemas cuantitativos y se considerarse como una de las tareas finales del procesamiento de los datos. Una vez definido el experimento, recogidas y pre-procesadas las señales convenientemente, y definido el vector de características representativo, el paso siguiente es la implementación de un clasificador que pueda decidir a qué clase corresponde cada una de las señales. La entrada de este clasificador es el conjunto de características (patrón de entrada) extraídas en el paso anterior (extracción de características, con reducción de dimensionalidad si es necesario), y la salida es una indicación (índice) de la pertenencia de un objeto a una clase u otra. El clasificador, es el encargado de asignar clases (índices) a dichos patrones de entrada y para conseguir este propósito, divide el espacio de entrada en regiones de decisión en donde idealmente, todos los patrones de una misma clase se agruparán en la misma zona del espacio de medida sin que exista una superposición entre las distintas agrupaciones formadas por otras clases. Entre las técnicas más comunes utilizadas en procesos de clasificación están:

- **Clasificador Bayesiano:** las incógnitas de interés siguen una distribución probabilística y permite realizar una valoración de la posibilidad de ocurrencia de una hipótesis de manera cuantitativa. Este clasificador, requiere una pequeña cantidad de datos de entrenamiento para estimar los parámetros pero requiere de un conocimiento a priori del sistema, además su coste computacional es alto. Una aplicación de este clasificador para señales biomédicas están descritas por Pino, et al. (2009), el cual se encuentra en el apartado 1.1.
- **Redes neuronales artificiales ANN:** son un modelo artificial y simplificado del cerebro humano, ya que tienen la capacidad de emular ciertas características como memorizar y asociar hechos. Dicho de otra manera, son capaces de adquirir conocimiento a través de la experiencia. Son un sistema de interconexión de neuronas que colaboran entre sí para producir

un estímulo de salida de acuerdo con una función de activación, estos sistemas no requieren de un modelo matemático, lo que las hace apropiadas para señales no estacionarias como las señales EMG. Una de las aplicaciones donde se utilizó redes neuronales artificiales para la de clasificación de señales biomédicas fueron hechas por Chen, Akutagawa, Emoto y Kinouchi (2010). Ellos centraron su investigación en filtrar señales EMG de señales EEG utilizando ANN, reduciendo el ruido blanco aditivo y multiplicativo de las señales pero conservando sus características. Subasi (2013), utilizó redes neuronales con función de activación de base radial (Radial basis function networks-RBFN) para el diagnóstico de desórdenes neuromusculares. En este estudio se realizó una comparación entre distintas técnicas de clasificación las cuales se describen en el apartado 1.6. Sin embargo, las redes ANN requieren de un gran número de muestras y mucho tiempo de entrenamiento para un aprendizaje adecuado (Romo, Realpe y Jojoa, 2007)

- **Máquinas de vectores de soporte (support vector machine-SVM):** son un algoritmo que elabora una frontera de decisión alrededor de los datos de aprendizaje y realiza un mapeo de puntos de entrada a un espacio de características de una dimensión mayor, para luego encontrar el hiperplano que los separe y maximice el margen entre las clases buscando la máxima separación. Un ejemplo del uso de SVM para clasificación de señales biomédicas es descrito por Alkan y Günay (2012). En este trabajo, se propone una técnica de clasificación para el control de una prótesis de brazo utilizando señales EMG de superficie. Este trabajo utilizó registró señales EMG generados por los músculos bíceps y tríceps durante cuatro movimientos diferentes flexión incluido codo, extensión del codo, pronación del antebrazo y supinación del antebrazo. Cada señal tiene un patrón único y es esencial separar y clasificar estos patrones correctamente. El análisis discriminante y las SVM se emplearon para clasificar los cuatro movimientos del brazo, utilizando como entrada los vectores de características generados a partir del cálculo del valor absoluto medio

(VAM) de cada patrón. Al conjunto de datos se le aplicó la técnica de validación cruzada (Cross validation-CV), la cual consiste en dividir el conjunto de datos en dos grupos, uno de entrenamiento y el otro de muestra y se utiliza para evaluar los resultados del análisis estadístico garantizando que los datos sean independientes. La CV fue de 10-fold, encontrando una precisión del 99% con un error de  $\pm 1\%$  utilizando un kernel lineal, y con esta tasa de clasificación alta se pudo concluir que, la metodología se puede utilizar para clasificar señales EMG aplicadas al control de prótesis de brazo.

- **Lógica Difusa;** son sistemas de inferencia (juicio a partir de hechos) que simulan la forma en que los seres humanos toman decisiones y además, tienen la posibilidad de introducir la opinión de un experto en la elaboración de reglas de decisión en el mismo esquema. Una aplicación que utiliza esta técnica de clasificación para señales EMG la describen Mebarkia, Bekka, Reffad y Disselhorst-Klug (2014) donde, se logró identificar los PAUMs Laplacianos aislados basado en rasgos morfológicos por medio un clasificador difuso. Las señales EMG fueron adquiridas con electrodos de superficie de tres músculos, el abductor corto del pulgar, el primer interóseo dorsal y el bíceps braquial de 11 sujetos sanos. Las características utilizadas se dividieron en dos grupos, el primero se definió como parámetros morfológicos visibles (amplitud, duración, curvatura y pendiente) y el segundo como parámetros morfológicos ocultos (amplitud, duración, curvatura y pendiente) después de derivar la señal. Par validar los datos se utilizó un a CV de 10-fold y para la clasificación se utilizó MSV y cinco algoritmos de análisis discriminante (lineal, diagonal, cuadrático, diagonal-cuadrático y Mahalanobis), a los cuales se les realizó un ajuste de los grados de certeza de reglas difusas mediante algoritmos genéticos (GA). Los resultados de precisión (Accuracy-Acc(%)) oscilaron entre 96% y 99%, con una tasa de error del 4% al 1%, siendo el resultado más bajo para el discriminante de Mahalanobis y el mejor para la SVM con un Kernel de función de núcleo ( $Ker(X_i X_j)$ ).

- **Sistemas Neurodifusos:** la combinación de redes neuronales y lógica difusa permite una relación simbiótica en la cual se aprovecha el conocimiento de un experto, la capacidad de aprendizaje y la eficiencia computacional de la red neuronal, logrando así un sistema de decisiones (Hu, Wang, Wu, Du, He y She, 2015).
- **Clasificador K vecinos más cercanos (K-nn):** es un método de clasificación no paramétrico basado en el reconocimiento de patrones con criterio de vecindad. Este criterio parte de la idea de que una nueva muestra será clasificada en la clase a la cual pertenezca la mayor cantidad de vecinos ( $K$ ) o conjunto de entrenamiento más cercanos. Este método de clasificación se ha utilizado en distintas aplicaciones como el descrito por Saini, Singh, y Khosla (2013), donde se utilizó un K-nn con  $K=3$  vecinos y una CV de 5-fold para detectar despolarización de los ventrículos del corazón en señales ECG, alcanzando una Acc (%) del 99.89, el cual se estableció como fiable y preciso. Por otra parte Ghaderyana, Abbasia y Hossein (2014), desarrollaron una metodología para la previsión de crisis basado en el análisis de señales de electroencefalografía, para lo cual se tomaron muestras de 21 pacientes con epilepsia focal médicamente intratable, los datos fueron adquiridos con una frecuencia de muestreo de 256 Hz, 128 canales y 16 bits de resolución. La descomposición de las señales se realizó mediante la transformada de Fourier en tiempo corto, obteniendo características lineales en cada sub-banda y debido a la gran cantidad de información resultante se aplicó PCA, y con ella se procedió a clasificar las señales con el fin de detectar se hay o no una convulsión en cada en cada paciente, para esto se realizó una CV de 5-fold y una búsqueda por grilla para optimizar los parámetros, encontrando un Acc (%) del 100 con el clasificador K-nn, confirmando la capacidad de discriminación de este algoritmo el cual fue simple, eficaz y con bajos requerimientos computacionales y demostró que esta metodología puede utilizarse potencialmente en los dispositivos implantables. Christodoulou, Kaplanis, Murray, Pattichis, Pattichis y Kyriakides (2012), muestran el uso

del K-nn con  $K=5$  en la clasificación de señales de superficie de EMG con un análisis multi-escala de análisis AM-FM para diferenciar entre pacientes normales y miopáticos o neuropáticos. Las grabaciones fueron adquiridas de 20 sujetos NOR y 20 pacientes con trastornos neuromusculares (11 con miopatía y 9 casos de neuropatía). Los datos fueron recolectados en el Departamento de Neurofisiología Clínica en el Instituto Chipre de Neurología y Genética. Un sistema de medición de fuerza calibrado con un peso total de 40 kg, se colocó en el extremo de los pies de un sofá, que se utiliza para los sujetos acostarse. Los pesos fueron levantados a través de una correa colocada en la muñeca y conectado al sistema a través de un transductor de fuerzas conectado directamente a un circuito de calibración. A cada paciente se le pidió que tirara del sistema realizando contracción voluntaria máxima (CVM) por tres veces con un intervalo de 2 minutos para evitar la fatiga. Las Grabaciones se hicieron con cinco niveles de fuerza diferentes, en 10%, 30%, 50%, 70% y 100% de la CVM del músculo bíceps. Para la descomposición de las señales se utilizaron representaciones multi-escala AM-FM, con el fin de describir el comportamiento de la señal no estacionaria. Se extrajeron características como amplitud instantánea (IA), fase instantánea (IP) y frecuencia instantánea (MI). Las cuales fueron normalizadas para evitar el sesgo de los clasificadores utilizados, K-nn con  $K=11$ , mapa de auto organización (SOM) y SVM. Las medidas de desempeño utilizadas fueron Acc (%), Sen (%) y Sp (%). Para el K-nn se obtuvo un Acc(%)= 75, con SOM un Acc(%)= 75 y con SVM un Acc(%)=78.

En la etapa de clasificación se debe tener en cuenta ciertas consideraciones a la hora de seleccionar el tipo de clasificador adecuado para la aplicación (Sandoval y Varila, 2007) como:

- **Exactitud ó Precisión:** representa el nivel de desempeño del clasificador, usualmente representado como la proporción de clasificaciones correctas que es capaz de producir.

- **Velocidad ó rapidez:** es el tiempo que toma hacer la clasificación bien sea en el entrenamiento o en la validación. En algunas ocasiones la velocidad es tan importante como la precisión, por ejemplo, un clasificador 90% correcto, sería preferible a uno 95% correcto, si el primero es 100 veces más rápido que el segundo.
- **Potencia de clasificación:** es la razón entre la tasa de éxito y el tiempo de procesamiento empleado, es decir, a mayor tasa de éxito y en menor tiempo, mayor es la potencia del clasificador.
- **Flexibilidad:** adaptabilidad del clasificador a un entorno cambiante. Debe ser capaz de adaptarse a señales provenientes de diferentes fuentes, sin que esto afecte su desempeño.

La elección del clasificador viene supeditada tanto al dominio del problema a tratar como a las consideraciones para la evaluación que tengan más relevancia según dicho dominio. Por esta razón es necesario tener en cuenta las características y la naturaleza de la información que se utiliza como datos de entrada del sistema y las condiciones ó características deseadas a la salida del mismo. En general, se requiere que el clasificador sea de baja complejidad, que opere de manera rápida, y posea buena capacidad de generalización, es decir, que sea capaz de hacer predicciones con otros datos no presentes en el entrenamiento.

## 1.6 Influencia de la Transformada Wavelet en la descomposición de señales EMG

La transformada Wavelet se ha venido utilizando con frecuencia en la descomposición de señales biomédicas. Una de las investigaciones es descrita por Subasi (2013), donde fueron clasificadas señales EMG para el diagnóstico de enfermedades neuromusculares. Las señales fueron adquiridas del músculo bíceps braquial utilizando un electrodo de aguja concéntrica. La señal fue preprocesada con un filtro pasa banda de 5 Hz a 10 kHz y se tomaron muestras a 20 kHz durante 5 segundos con una resolución de 12 bits. Todas las mediciones de los pacientes y del grupo control se realizaron en el Departamento de Neurología de la Universidad de Gaziantep. La base de datos estaba conformada por 27 sujetos, los cuales fueron separados en tres clases; una con 7 sujetos sanos (tres hombres, cuatro mujeres) con edades entre los 10 y 43 años; otra con 7 pacientes (cuatro hombres y tres mujeres) que presentaron miopatía (distrofia, atrofia muscular, miopatía inflamatoria muscular, miopatía proximal) con edades entre 7 y 46 años; una tercera clase constituida por 13 pacientes (ocho varones, cinco mujeres) con neuropatías (polineuropatía, síndrome del túnel carpiano, lesiones proximales del nervio mediano y el plexo braquial) con edades desde 7 a 55 años. La descomposición de las señales EMG, se efectuó mediante la familia Daubechies 4 de la Wavelet (DB4) con 5 niveles de descomposición donde las características calculadas fueron: la media de los valores absolutos de los coeficientes en cada sub-banda, la potencia media de los coeficientes de onda, la desviación estándar de los coeficientes y la relación entre los valores medios absolutos de sub-bandas adyacentes. Para la validación se utilizó una CV de 10-fold y tres técnicas distintas de clasificación, la primera con SVM obteniendo un Acc (%) del 96.75, la segunda con el clasificador K-nn con  $K=5$  alcanzando un Acc (%) del 95.17 y una tercera con redes de función de base radial (Radial basis function networks-RBFN) encontrando un Acc (%) del 94.08.

Utilizando la misma base de datos descrita anteriormente, Subasi (2012) realizó una comparación de diferentes métodos de extracción de características (modelos auto-regresivos (AR), DWT y WPT) y combinaciones de ellos (AR+DWT, AR+WPT y DWT+WPT). Con los modelos AR se extrajeron características de amplitud y magnitud; con la DWT se extrajo la media de los valores absolutos de los coeficientes en cada sub-banda, la potencia media de los coeficientes de onda, la desviación estándar de los coeficientes y la relación entre los valores medios absolutos de sub-bandas adyacentes; con el WPT se calculó la energía de la señal EMG. Con la combinación de estas características se procedió a aplicar un algoritmo de ajuste de los pesos de las neuronas de propagación hacia atrás, el ciclo terminó cuando el error de entrenamiento se estabilizó. Una vez entrenada la red, se utilizó una CV para determinar la medida de clasificación en todos los folds. Para la clasificación se utilizaron distintos sistemas neuro-difusos, el primero de estos sistemas fue la red neuronal multicapa (Multilayer Perceptron Neural Network-MLPNN) con la que se logró un Acc (%) del  $93 \pm 6$  para la combinación de características AR+DWT; con la red neuronal difusa dinámica (Dynamic fuzzy neural networks-DFNN) se obtuvo un Acc (%) de  $94 \pm 6$  para la combinación de AR+DWT; para el sistema adaptable de inferencia neuro-difusa (Adaptive Neuro Fuzzy Inference System –ANFIS) se logró un Acc (%) de  $95 \pm 4$  para la misma combinación de características, siendo este último el de mejor desempeño.

Por otra parte, Rafiee, Rafiee, Prause y Schoen (2011) muestran la utilidad de la Wavelet madre para la descomposición de distintas bioseñales como EMG, EEG y la amplitud del pulso vaginal (vaginal pulse amplitude-VPA). Los registros de las señales EMG proporcionados por el Instituto de Ingeniería Biomédica de la Universidad de New Brunswick, con un protocolo aprobado por la Junta de Ética de Investigación de la Universidad (Hargrove, Englehart, y Hudgins 2007), fueron capturados en forma intramuscular y superficial. Para las señales de EMG de superficie, se utilizó una matriz lineal con 16-electrodos a una distancia entre ellos de 2 cm y se filtró cada canal entre 10 y 500 Hz. Para los registros intramusculares, se implantaron agujas en los músculos pronador y supinador,

flexor, extensor, flexores y extensores del carpo. Estos se utilizaron para registrar información con respecto a agarre, flexión de la muñeca, rotación, y el movimiento bruto. Los 6 canales de datos se filtraron entre 10 y 3000 Hz y se amplificó con una ganancia de 2000. Las señales EEG fueron registradas a partir de tres electrodos monopolares esto con el propósito de registrar los potenciales evocados visuales. Todas las señales de EEG analógicas de los tres canales se convierten a formato digital a través de un convertidor A/D con una velocidad de muestreo de 300 Hz, y luego amplificada por 5000. Las señales fueron filtradas utilizando un filtro de paso alto a 10 Hz y un filtro de paso bajo a 30. En cuanto a las señales de VPA, fueron adquiridas mediante el sistema de adquisición de datos Biopac (Modelo MP100). La primera señal fue filtrada por un pasa banda entre 0,5 y 30 Hz y la tasa de muestreo se fijó en 80 Hz. Para la descomposición de las señales se utilizaron 324 Wavelet madre en busca de la función más similar y se encontró que la DB44 fue la función Wavelet madre más similar para las clases.

Continuando con la influencia de la transformada Wavelet en la descomposición de señales electromiográficas, Jaimes, Durán y Mendoza (2010), proponen una metodología para la caracterización de señales EMG aplicada a la cuantificación de unidades motoras en pacientes que presentaron el síndrome del pie caído, el cual es un trastorno neuromuscular (nervio y músculo) que afecta la capacidad del paciente de levantar el pie a la altura del tobillo y puede estar acompañado por dolor, debilidad y entumecimiento. Las señales electromiográficas se obtuvieron de 12 pacientes con electrodos de superficie ubicados en el músculo tibial anterior, provenientes de contracciones isométricas con una duración de 4 segundos y digitalizadas a una frecuencia de muestreo de 10 KHz. Para la descomposición de las señales se utilizó la DB5 con 7 niveles de descomposición y teniendo en cuenta el conteo de unidades motoras y la amplitud de la señal, se encontró un Sen (%) del 80%.

Teniendo en cuenta la literatura encontrada, se logra evidenciar el uso de la WT y específicamente de la familia Daubechies como ayuda diagnóstica. Además, los

sistemas de apoyo a las decisiones de diagnóstico pueden llegar a ser útiles cuando el juicio del médico depende de alguna otra prueba, ya que reducen la necesidad de las mismas (Subasi, 2012).

## **1.7 Recomendaciones**

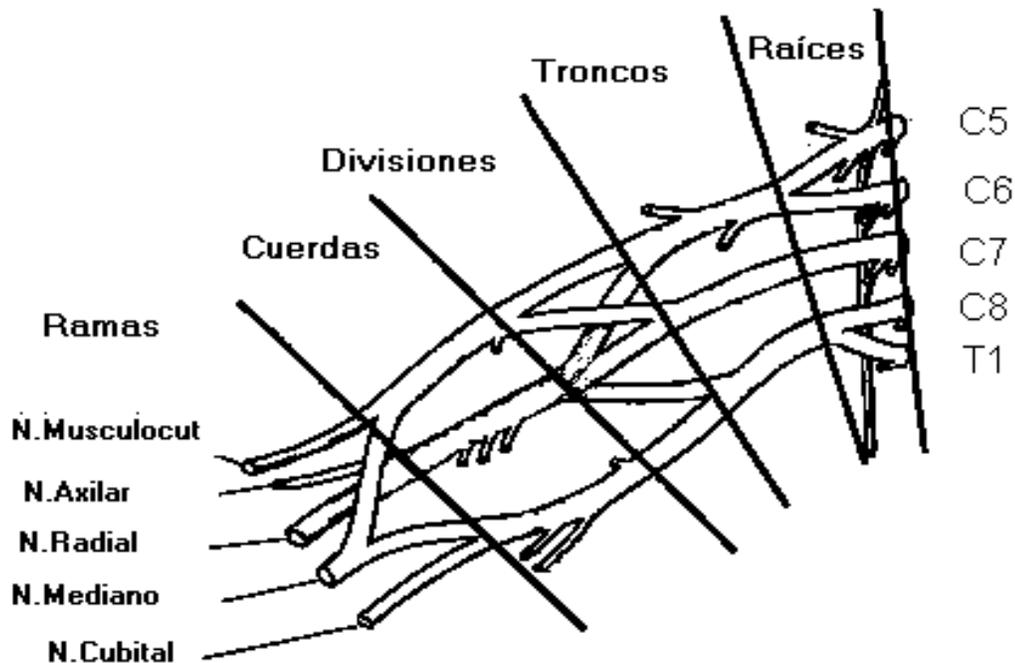
Aunque la electromiografía cuantitativa ha venido siendo estudiada aplicaciones basadas en el análisis de señales biomédicas, los grandes conjuntos de datos implicados en el análisis cuantitativo de las señales EMG hacen difícil la extracción manual de una caracterización de utilidad clínica. Aumentar las técnicas existentes de QEMG permitirán obtener una caracterización que sea sensible a los cambios causados por una enfermedad neuromuscular, llevaría a un más amplio uso clínico de las técnicas cuantitativas y permitiría a los médicos medir con mayor precisión el nivel de afectación de la enfermedad y así, evaluar el tratamiento con efectividad (Pino, Stashuk, Boe y Doherty, 2009).

Por lo expuesto anteriormente, realizar una aproximación cuantitativa de la prueba de electromiografía; permitiría obtener resultados más concluyentes que pueden evitar potencialmente la invasión al paciente lesionado, ubicar con mejor exactitud la raíz o raíces afectadas, la gravedad de la lesión y establecer simultáneamente un pronóstico de funcionalidad motora de la o las extremidades comprometidas. Con esto se lograría un proceso de caracterización que permita que las decisiones tiendan a ser fáciles de entender, produciendo un valor numérico en apoyo o refutación de la caracterización de EMG y lograr así la generalización.

## 2. Preliminares teóricos

### 2.1 Plexo braquial

El plexo braquial está constituido por una compleja unión de las ramas ventrales de los nervios espinales C5, C6, C7, C8 y D1, con las aportaciones ocasionales de C4 y D12; como consecuencia de estas uniones se forman los denominados troncos, fascículos y nervios terminales del plexo. El tronco superior se forma por la unión de las ramas ventrales de los nervios espinales C5 y C6, el tronco medio por la rama ventral del nervio espinal C7 y el tronco inferior por las ramas ventrales de C8 y D1. Las divisiones del tronco superior y medio confluyen formando el fascículo medial o externo que discurre por la porción externa de la arteria axilar. Contiene, así, los nervios espinales C5, C6 y C7 descritos por Bollini (2004), como se muestra en la Figura 1.



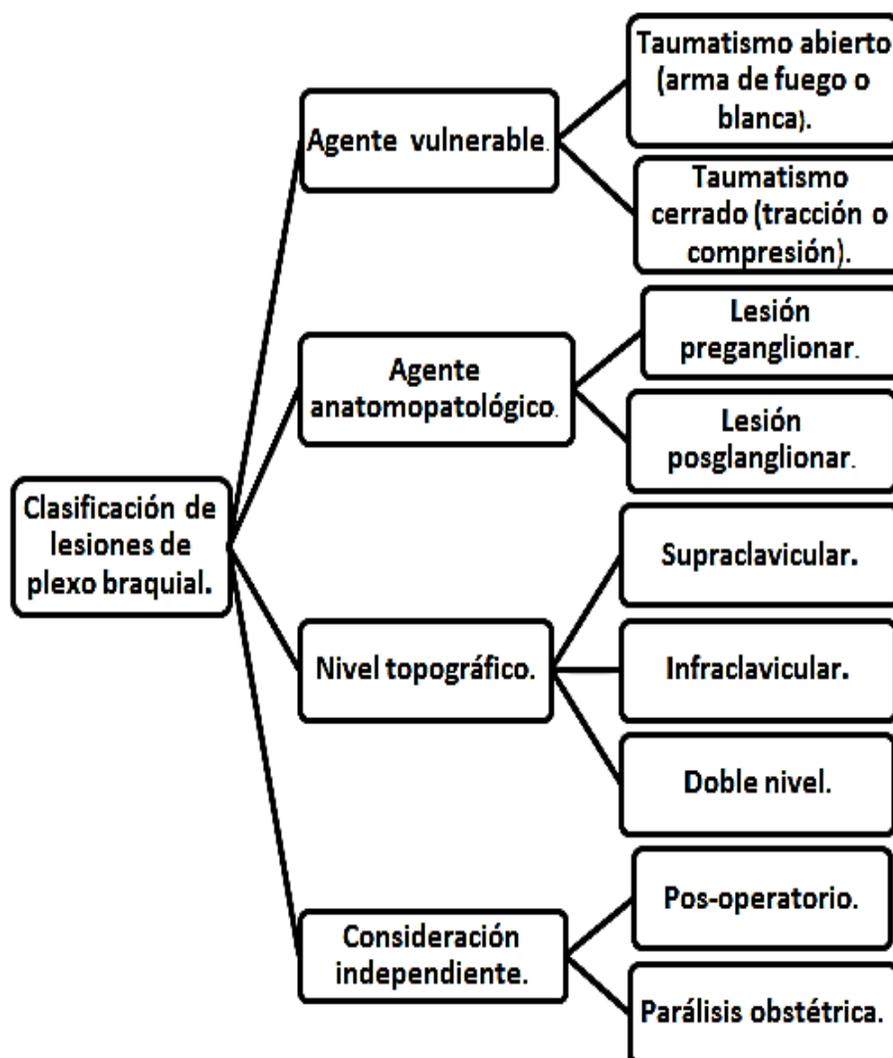
**Figura 1. Esquema de plexo braquial**

**Fuente:** Romero, Parálisis Braquial Obstétrica. Recuperada de [www.cirugiamano.com/pbo/](http://www.cirugiamano.com/pbo/)

### 2.1.1 Lesión de plexo braquial

Es una lesión en uno o más nervios localizados entre el cuello y el hombro (Dogliotti, 2011), también se conoce en el idioma inglés como "stinger" o quemazón. Estas lesiones pueden ser causadas por la ocurrencia de dos eventos: el hombro es empujado hacia abajo al mismo tiempo que la cabeza del paciente es forzada hacia el lado opuesto, lo cual estira los nervios entre el cuello y hombro; la cabeza se mueve rápidamente en una dirección presionando los nervios de esa área. El esquema de clasificación de las lesiones de plexo braquial se muestra en la Figura 2.

**Figura 2. Algoritmo de Clasificación de las lesiones de plexo braquial**



Las lesiones post-ganglionares tienen tratamiento. En estos casos se reseca la lesión y se colocan injertos, libres o vascularizados, dependiendo de la localización, del grado de defecto y del número de troncos nerviosos (Limthongthang, Bachoura, Songcharoen y Osterman, 2013). Como el plexo braquial se conforma de cinco salidas de raíces, de la C5 a la T1, según el número que estén lesionadas, se pueden hacer distintas maniobras para reconstruir en lo posible las funciones perdidas (Chuang, 2008). Actualmente, se consiguen buenos resultados en la funcionalidad del hombro, la escápula, en la flexión del codo y en la estabilidad de la muñeca (Vergara, 2010). Los resultados no son adecuados para las funciones de la mano (Amador, 2010), ya que son nervios que se inician en un nivel muy proximal y puesto que la velocidad de regeneración del nervio es muy lenta (un milímetro por día), la reinervación no llega, o lo hace muy tarde y no se puede recuperar la funcionalidad (Oberlin, Chino y Belkheyar, 2013). En el caso de las lesiones abiertas hay que operarlas de inmediato, a diferencia de las cerradas. En las primeras hay una sección del nervio y se debe evitar que este se retraiga; en las cerradas, que son las más frecuentes, no se pueden operar de inmediato debido a que para identificar dónde está la lesión y prever exactamente el grado de evolución espontánea (reinervación) hay que esperar 3 meses como mínimo y 6 como máximo. A partir del año, la microcirugía no obtiene resultados y solamente es eficaz la cirugía paliativa.

En los traumatismos abiertos por arma blanca y en los que existen secciones limpias del plexo, se realiza una exploración neuroquirúrgica del plexo braquial, siempre y cuando el diagnóstico clínico no sugiera una lesión del tronco inferior cuyo pronóstico es muy malo. Cuando se presentan lesiones por arma de fuego de baja energía cinética y sin lesión vascular asociada, se puede tomar la decisión de esperar o hacer una exploración del plexo. Por arma de fuego de alta energía cinética la indicación quirúrgica es discutida dado que el efecto explosivo hace imposible precisar la extensión de la lesión.

Cuando ocurren traumatismos cerrados, el tratamiento de las lesiones del plexo braquial es muy complejo (Van Alfen y Martijn, 2013), incluyendo su diagnóstico, el cual depende del seguimiento sistemático de la evolución de las lesiones, medidas ortopédicas, de rehabilitación y posibles indicaciones quirúrgicas, tanto neurológicas como ortopédicas, por lo que debe ser organizado generalmente de modo multidisciplinario. Según el aspecto anatomopatológico es fundamental la exploración neurológica, así como, hacer un seguimiento a la evolución de las pérdidas neurológicas.

En el diagnóstico de una lesión de plexo braquial, se utilizan una serie de métodos (ayudas diagnósticas) que se referencian a continuación.

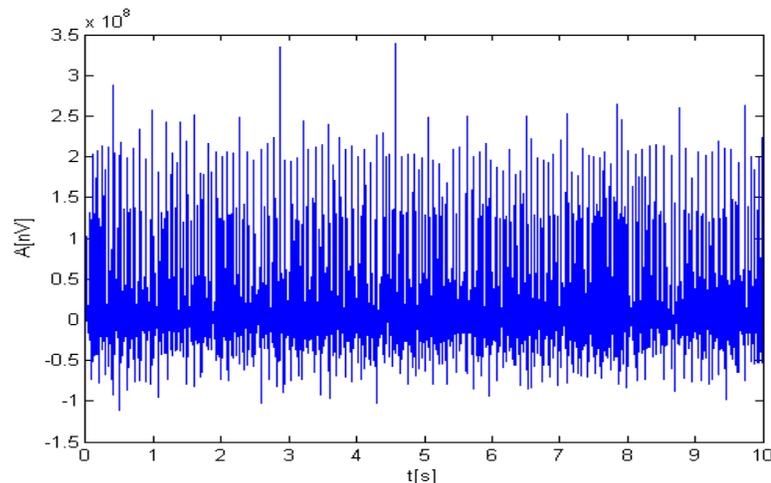
- Signos clínicos motores: se pueden dar por parálisis del músculo serrato, lo cual presume una lesión pre-ganglionar de C5 y C6 o una parálisis del romboide que prevee lesión pre-ganglionar de C5.
- Signos vegetativos: Prueba de la histamina-Lewis, positiva en el dermatoma correspondiente a una lesión pre-ganglionar; esta trata de una respuesta refleja que requiere fibras aferentes intactas.
- Signo de Tinel: Indica la presencia de axones en el neuroma proximal.
- Signos radiológicos: se miden por medio de la mielografía cervical que permite una visualización indirecta de las lesiones yuxtamedulares por separación.
- Signos EMG (electromiógrafos): los cuales se pueden obtener con una prueba de velocidades de conducción nerviosa (VCN), la cual ayuda a determinar si permanece alguna integridad en los nervios mediano o cubital o de la porción sensitiva de los nervios radiales. Otra forma es usando la electromiografía EMG que se refiere al registro de la actividad eléctrica generada por el músculo, ayuda a determinar si una lesión es pre o post-ganglionar, el número de raíces afectadas, severidad del daño y los signos de re-inervación.

## 2.2 Electromiografía clínica

Es una metodología de registro y análisis de la actividad bioeléctrica del músculo, orientada al diagnóstico de enfermedades neuromusculares, la cual proporciona una importante fuente de información para el diagnóstico de los trastornos neuromusculares (Kaur, 2010).

La exploración EMG se realiza incrustando un electrodo de aguja en el músculo y se procediendo con el registro como se aprecia en la Figura 3. El registro de la señal bioeléctrica se realiza en tres estados: *en reposo*, esto se da cuando el músculo se encuentra completamente relajado y no debe registrarse ninguna actividad. (*Contracción débil*), la cual debe sostenerse para registrar unidades de potencial motoras (PAUMs). Con ello activa un número de unidades motoras (UMs) y pueden captarse las descargas de los PAUMs. *Contracción voluntaria máxima*, cuando la actividad EMG o actividad mioeléctrica alcanzada durante una contracción máxima informa sobre la población de UMs funcionales. En conjunto, la señal EMG traduce las remodelaciones patológicas de las UMs, las variaciones respecto a los patrones normales en cada músculo, junto con la valoración de otros datos neurofisiológicos y el contexto clínico de cada paciente. Todo lo anterior, constituye la base del diagnóstico EMG (Gila, Malanda y Navallas, 2009).

**Figura 3. Señal EMG**



A pesar de los grandes avances en cuanto al diagnóstico y la microcirugía, no es posible reparar satisfactoriamente todas las lesiones del plexo braquial (Amador, 2010). Hoy en día hay una barrera insuperable que se da cuando las lesiones están dentro del canal o la médula, lo que se denomina lesiones de separación o pre-ganglionares (Oberlin, Chino y Belkheyar, 2013).

Cuando se diagnostica una lesión por traumatismo cerrado, lo cual se hace mediante métodos invasivos (como la Electromiografía –EMG) (Mannan y Carlstedt, 2006), pueden ocurrir problemas con el diagnóstico debido a que dichos métodos generan resultados no concluyentes y tienen una variabilidad inter-sujeto, es decir, el examen puede ser interpretado de diferentes maneras si es leído por más de un experto para localizar la zona, la raíz nerviosa lesionada y la severidad de la lesión. Esto causaría un reproceso en la información, un mal diagnóstico y en el peor de los casos un mal procedimiento quirúrgico (exploración invasiva), sin mencionar los costos que esto acarrea. Hacer una aproximación cuantitativa de dicha prueba permitiría obtener resultados más concluyentes que puedan establecer un pronóstico de funcionalidad.

### **2.3 Transformada Wavelet (WT)**

La Transformada Wavelet es una herramienta para la representación de señales no estacionarias, proporcionando un análisis multiresolución con ventanas dilatadas. La principal ventaja de esta transformada frente a la transformada de Fourier es la variabilidad en el tamaño de las ventanas, las cuales se ajustan según las frecuencias. Específicamente, la ventana es amplia si las frecuencias son bajas y se estrecha si las frecuencias son altas, permitiendo una resolución de tiempo- frecuencia que se puede adecuar para todos los rangos de frecuencia.

### 2.3.1 Transformada Wavelet Continua (CWT)

Esta transformada opera de forma similar a la Transformada e Fourier en Tiempo Corto (STFT), donde cada señal es multiplicada por una función Wavelet de manera similar a la función ventana de la STFT, la cual se calcula separadamente para distintos segmentos de la señal en el dominio del tiempo y se define como:

**Ecuación 1.** Transformada Wavelet Continua

$$C(\tau, s) = \int_{-\infty}^{+\infty} f(t) \Psi_{\tau, s}(t) dt$$

Donde  $\Psi$  es la Wavelet madre,  $s$  es el factor de escala y  $\tau$  es el factor de traslación.

**Ecuación 2.** Wavelet madre  $\Psi$

$$\Psi_{\tau, s}(t) = \frac{1}{|s|} \Psi\left(\frac{t - \tau}{s}\right)$$

Donde  $s, \tau \in \mathbb{R}$ ,  $s \neq 0$  y  $s$  es una variable de escala, que permite comprimir o dilatar la función  $\Psi_{\tau, s}(t)$ ,  $\tau$  es una variable de traslación que permite desplazar la función  $\Psi_{\tau, s}(t)$  y determina su ubicación sobre la señal analizada.

### 2.3.2 Transformada Wavelet Discreta (DWT)

La DWT analiza la señal en diferentes bandas de escala (bandas de frecuencia), con diferentes resoluciones por la descomposición de la señal en componentes de aproximación y de detalle. La DWT emplea dos conjuntos de funciones llamadas funciones de escala y funciones de tren de ondas, que se asocian con filtros de paso bajo y filtros de paso alto, respectivamente. La descomposición de

la señal en diferentes bandas de frecuencia se obtiene por medio de la aplicación sucesiva de filtros de paso bajo y de paso alto. La DWT se describe matemáticamente en la Ecuación 3.

**Ecuación 3.** Transformada Wavelet Discreta.

$$X t = \sum_{k=-\infty}^{k=+\infty} C_{n,k} \phi(2^{-n}t - k) + \sum_{j=1}^n \sum_{k=-\infty}^{k=+\infty} d_{j,k} 2^{-j/2} \Psi(2^{-j}t - k)$$

Donde  $C_{n,k}$  son los coeficientes de escala y  $d_{j,k}$  son los coeficientes Wavelet de la señal original  $X t$ , con respecto a las funciones de escala  $\phi(2^{-n}t - k)$  y a la Wavelet  $\Psi(2^{-j}t - k)$  respectivamente.

Los coeficientes derivados de la descomposición Wavelet son numerosos para ser utilizados como características para la clasificación, por lo que se hace necesario realizar un análisis que permita reducir la cantidad de información resultante de esta descomposición, con el fin de usar sólo la información relevante.

## 2.4 Análisis de relevancia

El análisis de la relevancia distingue las variables que son efectivas representando los fenómenos fisiológicos subyacentes acordes a alguna medida de evaluación, denominada Relevancia de la Característica. Éste intenta rechazar las características en las que su contribución sea poca o nula (características irrelevantes), así como aquellas que tienen información repetida (características redundantes). Por lo tanto, luego de la selección de características en el contexto de cualquier inferencia, lo más importante es la definición de la relevancia. Si  $X_{\xi} \in R^{N \times p}$ ; es un objeto comprendido con  $N$  muestras de observación que se describen por una característica  $p$  - dimensional agrupada en  $\xi = \{\xi_i: i = 1, \dots, p\}$ . Además, cada muestra está asociada a una única etiqueta de clase agrupada en

un vector  $C = \{C_k \in N: K = 1, \dots, K\}$ , donde  $K$ , es la suma de las clases bajo consideración. Luego, dado  $X_\xi$ , y para cada una de las características de  $\xi_i \in \xi$ , la función de relevancia  $g$  está definida como:

**Ecuación 4.** Función de relevancia.

$$g: R^{N \times p} \times \xi \rightarrow \mathbb{R}$$

$$X_\xi, \xi_i \rightarrow g(X_\xi, \xi_i) \in \mathbb{R}$$

Donde  $X_\xi$  es la matriz de características y  $\xi_i$  representa cada una de ellas.

Dicho de otra manera, el análisis de relevancia permite eliminar las características menos significativas y permite la obtención de un subconjunto que contienen suficiente información para poder diferenciar correctamente las clases en la posterior clasificación (Roa y Loaiza, 2011). Existen diferentes métodos de análisis de relevancia como el análisis de componentes principales PCA, la entropía difusa, variabilidad estocástica, entre otras.

### 2.4.1 Análisis de Componentes Principales (PCA)

Es una técnica que busca transformar el conjunto original de variables cuando éstas se encuentran correlacionadas, con un número “ $p$ ” de características, por otro conjunto de nuevas características de cardinalidad “ $m$ ” (conjunto de componentes principales), que no tengan redundancia en la información no correlacionada. Idealmente se buscan  $m < p$ . Cuanto mayor sea la variabilidad de los datos (varianza) se considera que existe mayor información. En este trabajo se utilizó un criterio de varianza del 98% de los datos, se determinó como entradas, las características ( $\xi$ ) obtenidas de la matriz de señales EMG y como salidas las características transformadas ( $\zeta$ ) en un espacio vectorial, donde los primeros vectores contienen la mayor cantidad de variabilidad.

### 2.4.2 Entropía Difusa (ED)

De forma general la entropía mide la cantidad de incertidumbre en el resultado de un experimento aleatorio (Lee, Chen, Chen y Jou, 2001), puede ser interpretada como el grado de información de la observación de una variable que cuanto más aleatoria sea, más grande es su entropía  $H_y$ . Por lo tanto, las  $\xi$  que tengan menor  $H_y$  son las más relevantes y ésta información se convierte en la salida del sistema al aplicar la técnica de ED. Al estar relacionada  $H_y$  con la longitud de la codificación de la variable aleatoria, se puede definir como:

#### Ecuación 5. Entropía

$$H_y = - \sum P(Y = a_i) \log P(Y = a_i)$$

Donde  $a_i$  son los posibles valores de  $Y$ , y  $P$  es la probabilidad de  $a_i$ .

La entropía difusa permite decir qué tan dispersos están los elementos del conjunto, según la función característica en cada punto del universo en el que está contenido (Lee et al. 2001).

Esta medida tiene importancia para la investigación que se presenta en cuanto a la decisión y selección de características asociadas a la separabilidad. Se ha sugerido distintas definiciones de entropía difusa, De Luca y Termini (1972), sugieren qué, con respecto a la entropía de Shannon la medida de entropía difusa es:

#### Ecuación 6. Medida de la entropía difusa

$$H_1 A = - \sum_{j=1}^i \mu_A x_j \log \mu_A x_j + (1 - \mu_A x_j) \log (1 - \mu_A x_j)$$

Donde  $\mu_A x_j$  son valores de pertenencia,  $j$  y  $i$  son constantes  $\neq 0$ .

La entropía difusa se considera como una medida que evalúa las desviaciones globales de los tipos de conjuntos ordinarios, es decir, cualquier conjunto clásico  $A_0$  conduce a  $H(A_0) = 0$ . Note que el conjunto difuso  $A$  con  $\mu_A(x) = 0.5$  desempeña el papel de elemento máximo del orden definido por  $H$ .

Parkash, Sharma y Manahan (2008), definen la entropía difusa como se muestra en las ecuaciones 6 y 7.

**Ecuación 7.** Otras formas de la entropía difusa

$$H_2 A; w = \sum_{j=1}^i w_j \left( \sin \frac{\pi \mu_A X_j}{2} + \sin \frac{\pi(1 - \mu_A(X_j))}{2} - 1 \right)$$

$$H_3 A; w = \sum_{j=1}^i w_j \left( \cos \frac{\pi \mu_A X_j}{2} + \cos \frac{\pi(1 - \mu_A(X_j))}{2} - 1 \right)$$

Las ecuaciones antes descritas se utilizan en la selección de características obtenidas mediante la transformada Wavelet. Con ellas se puede evaluar la relevancia de cada rasgo y así realizar una reducción dimensional del sistema aduciendo que un valor de entropía alto contribuye poco a la desviación entre clases.

### 2.4.3 Variabilidad Estocástica (VE).

Cualquier característica estocástica  $\xi(t)$  se refiere a un valor numérico aleatorio que representa medidas cambiantes en función del tiempo; esto es, existe un conjunto de parámetros  $\xi = \{\xi_i(t) : i = 1, \dots, p\}$ , que cambian a lo largo del tiempo  $t \in T$ , y conlleva la información temporal de las señales no estacionarias. Debido al alto costo computacional del entrenamiento basado en características estocásticas, la reducción de dimensión de espacios se debe llevar a cabo, siendo las técnicas de variable latente ampliamente usadas para este fin

(Sepúlveda, Acosta y Catellanos, 2010). Estas transformaciones reducen el espacio de características estocásticas  $p$ -dimensional,  $\xi \in \mathbb{R}^{p \times T}$ , dentro de un conjunto estocástico de  $q$  dimensiones,  $\zeta \in \mathbb{R}^{q \times T}$ ,  $q \leq p$ , en el cual la mayor cantidad de información es preservada. Además, como peso de relevancia  $g$ , la medida de evaluación de la transformación está dada por variables que representan efectivamente el fenómeno fisiológico subyacente, denominadas características estocásticas relevantes. Dado un conjunto de características estocásticas,  $\xi = \{\xi_i(t) : i = 1, \dots, p\}$ , con la observación comprendida por  $N$  objetos que están dispuestos en la matriz de observación de entradas  $\mathbf{X}_\xi = [X_1 \dots X_i \dots X_N]$ , denotando cada objeto  $X_i$ ,  $i = 1, \dots, N$ , que es descrito por las respectivas observaciones de conjuntos de arreglos de variables en el tiempo,  $\{X_{ji} \in \xi, j = 1, \dots, p\}$ , de tal forma que  $X_i = [X_{1i} \dots X_{ji} \dots X_{pi}]^T$ ,  $X_i \in \mathbb{R}^{p \times T}$ , donde  $X_{ji} = [x_{ji} \ 1 \dots x_{ji} \ t \dots x_{ji} \ T]$ , es cada una de las medidas o características estimadas en tiempo-corto a partir de las señales, igualmente muestreado en evolución a través del tiempo y siendo  $x_{ji} \ T$ , la  $j$ -ésima característica estocástica para el  $i$ -ésimo objeto en un instante de tiempo  $t$ .

La reducción de dimensión se lleva a cabo cuando se proyecta el enfoque de variable latente. Dada la matriz de observación  $\mathbf{X}_\xi$ , existe una pareja de matrices ortonormales  $\mathbf{U}$ ,  $\mathbf{V}$ , además una matriz diagonal  $\zeta_x$ , de modo que la siguiente descomposición lineal tiene lugar.

**Ecuación 8.** Matriz Ortonormal.

$$\mathbf{X}_\xi = \mathbf{U}\zeta_x\mathbf{V}^T, \mathbf{U} \in \mathbb{R}^{N \times N}, \zeta_x \in \mathbb{R}^{N \times pT}, \mathbf{V} \in \mathbb{R}^{pT \times pT}$$

Donde  $\zeta_x \in \mathbb{R}^{pT \times pT}$  asegura el primer orden  $q$  como el más relevante de los valores propios de la matriz  $\mathbf{X}_\xi$ ,  $v_1 \geq v_2, \dots, \geq v_q \geq v_{q+1}, \dots, \geq v_{qT} \geq 0$ , que implica la medida relevante a ser considerada. Debe aclararse que inherentemente al enfoque básico de la variable latente, la medida mínima del error cuadrático es asumida como la medida evaluada de la transformación  $g \ \mathbf{X}_\xi, \mathbf{Z} \sim \min \mathbf{E} \{ \|\xi - \mathbf{Z}\|_2 \}$ , (donde  $\|\cdot\|_2$  es el valor cuadrático normal). Esto es,

una varianza máxima preferida como medida relevante, cuando la siguiente estimación de la matriz de covarianza es llevado a cabo (Sepúlveda et al. 2010).

**Ecuación 9.** Matriz de covarianza.

$$\text{cov } \mathbf{X}_\xi = \mathbf{X}_\xi^T \mathbf{X}_\xi = \mathbf{V} \boldsymbol{\zeta}_x^2 \mathbf{V}^T$$

Donde  $\mathbf{X}_\xi$  es la matriz de características,  $\boldsymbol{\zeta}_x$  son las características transformadas y  $\mathbf{V}$  en una matriz ortonormal.

Para hacer clara la contribución de cada valor variante en el tiempo,  $x_{ji} \ T$ , la Ecuación 8 puede ser extendida en la forma  $\mathbf{X}_\xi = \sum_{j=1}^q v_j U_j V_j^T$ , donde  $U_j$  es la columna  $j$  de la matriz  $U$ . Entonces, cada vector en el tiempo de la fila  $\tau = 1, \dots, p$  de  $\mathbf{X}_\xi$  es descrito por los términos de la suma de los respectivos valores propios  $\{v_j\}$ , lo cual es,  $\chi_\tau = \sum_{j=1}^q \lambda_{\tau j} V_j$ , siendo el  $\lambda_{\tau j} = v_j U_{\tau j}$  y  $U_{\tau j}$  un elemento de  $U$ . Cada vez la fila  $\tau$  de  $\mathbf{X}_\xi$  es un vector comprimido  $\tau/(T+1)$  más la primera variable estocástica, media sobre todo el objeto conjunto para un momento de tiempo  $t$  dado, donde  $\xi$  denota el número entero menor que o igual a  $\xi$ . Consecuentemente, la cantidad de varianza capturada en el instante de tiempo  $t$  por la descomposición del conjunto de valores propios es llevado a cabo como una medida de relevancia variante en el tiempo, los cuales se asocian a la varianza de la respectiva fila  $\tau$ , para cada característica en el eje tiempo (Sepúlveda et al. 2010).

**Ecuación 10.** Medida de relevancia.

$$g \ \mathbf{X}_\xi, \mathbf{Z}; \tau = \text{var } \chi_\tau$$

Donde  $g$  es el peso de relevancia,  $\mathbf{X}_\xi$  es la matriz de  $\xi$ ,  $\mathbf{Z}$  es la matriz de características transformadas y  $\text{var } \chi_\tau$  es la varianza acumulada.

## 2.5 Clasificador de K vecinos más cercanos (K-nn)

Este clasificador se conoce por su simplicidad y eficacia a pesar de que es sensible a los problemas de dimensionalidad (Friedman, 1997), situación que se puede corregir con un análisis de relevancia. Su objetivo principal consiste en seleccionar un punto de la clase dominante y tomar la distancia euclidiana entre sus vecinos más cercanos  $K$ , en el conjunto de entrenamiento, la cual está dada por:

**Ecuación 11.** Distancia euclidiana

$$d_{A,B} = \sqrt{A - B^2 A - B}$$

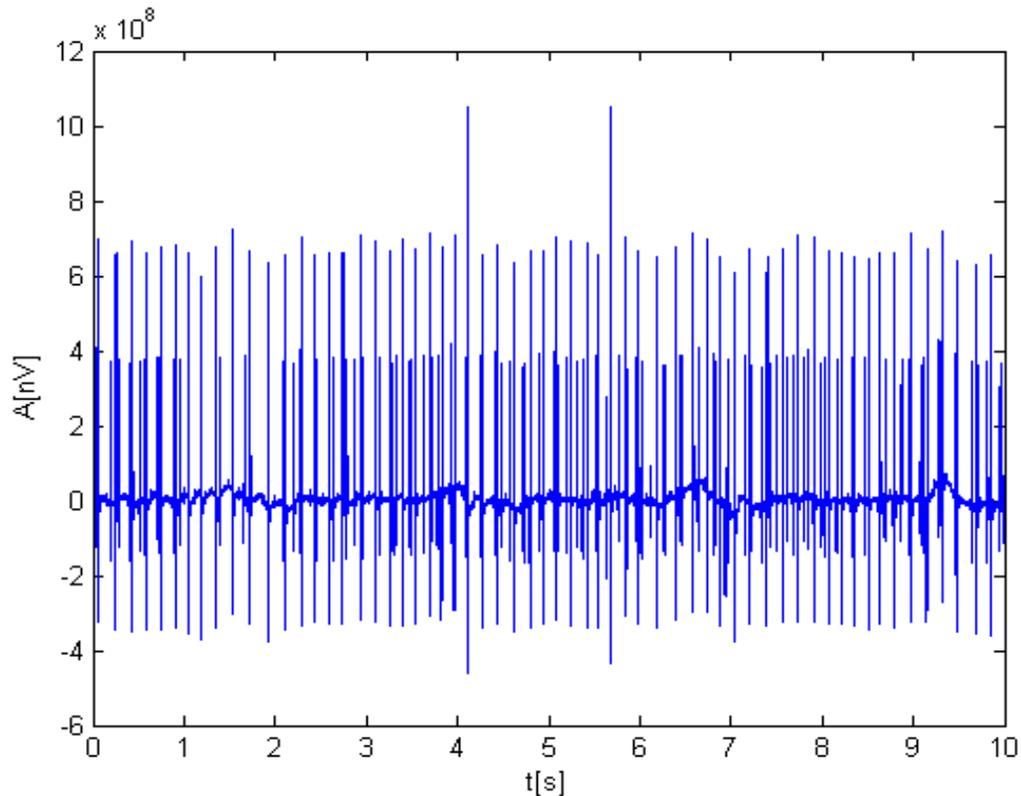
Donde A y B son puntos en el espacio de decisión.

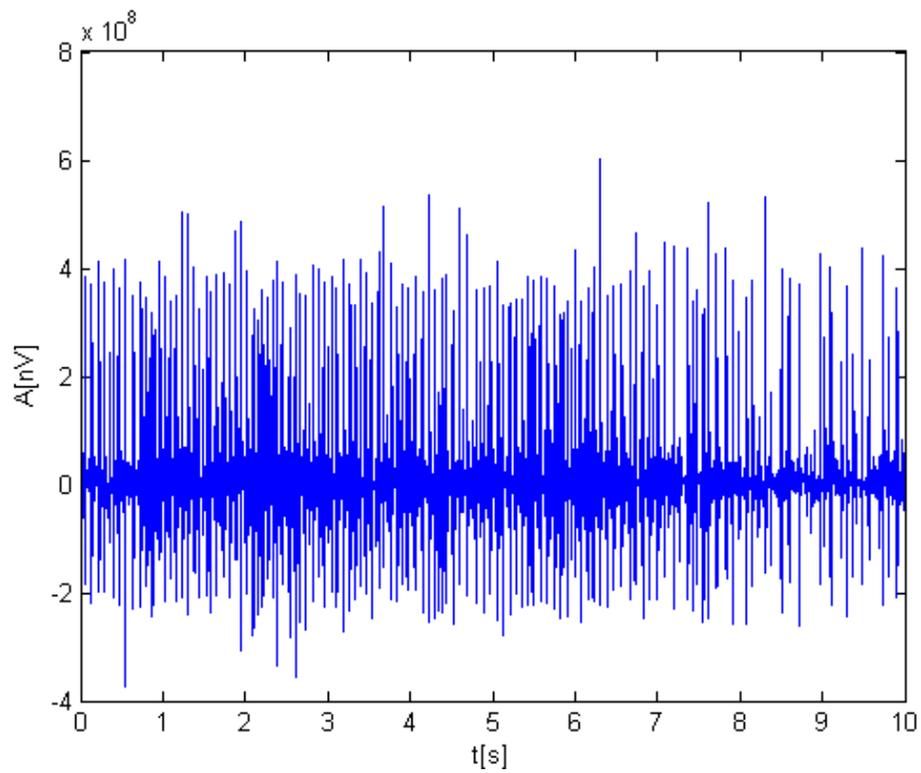
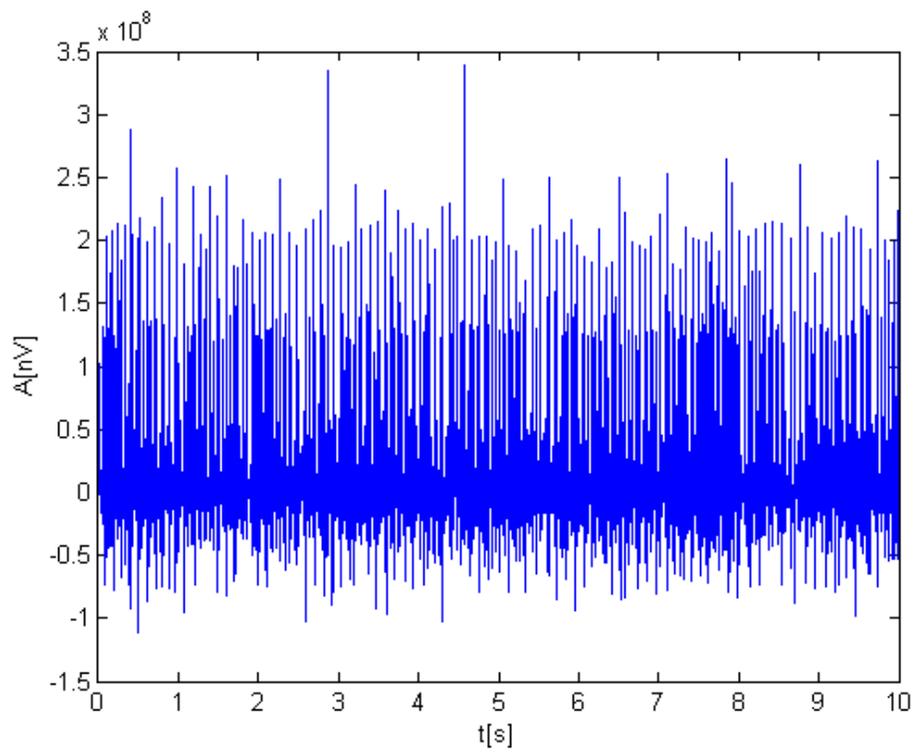
## 3. Marco experimental

### 3.1 Base de datos

La base de datos de las señales clínicas se obtuvo de una tesis doctoral desarrollada por Miki Nikolic en la Facultad de Ciencias de la Salud de la Universidad de Copenhague (Nikolic, 2001). El estudio consistió en un grupo de pacientes de control normales (NOR), de los cuales se muestra un registro de la señal EMG en la Figura 4. Un segundo grupo de pacientes con miopatía (Myopathy-MIO) de los cuales se muestra un registro de la señal EMG en la Figura 5 y un tercer grupo de pacientes con ALS de los cuales se muestra un registro de la señal EMG en la Figura 6.

**Figura 4. Señal EMG de paciente Normal.**



**Figura 5. Señal EMG de paciente Miopático.****Figura 6. Señal EMG de paciente con Esclerosis Lateral Amiotrófica.**

Las señales EMG de la base de datos fueron divididas en tres clases: un grupo de pacientes NOR con 270 registros tomados del bíceps braquial de 10 sujetos entre 21 a 37 años, 4 mujeres y 6 hombres, donde 6 de los 10 se ejercitaban con regularidad y los restantes 4 no realizaban actividad física. Ninguno en el grupo de control tenía signos o antecedentes de trastornos neuromusculares. El grupo con miopatía consta 82 registros tomados del bíceps braquial en 7 pacientes; 2 mujeres y 5 hombres de edades entre 19 a 63 años; todos los 7 tenían signos clínicos y electrofisiológicos de miopatía. Finalmente, el grupo ALS contiene 43 registros tomados en el mismo musculo de las otras clases y lo conformaron 8 pacientes; 4 mujeres y 4 hombres de edades entre 35 a 67 años. Además de los signos clínicos y electrofisiológicos compatibles con ALS, 5 de ellos murieron pocos años después de la aparición de la enfermedad, comprobando el diagnóstico de la ALS. El bíceps braquial y el músculo vasto medial fueron los más utilizados en este estudio y las señales EMG se registraron bajo las siguientes condiciones para el análisis del potencial de unidad motor PAUM:

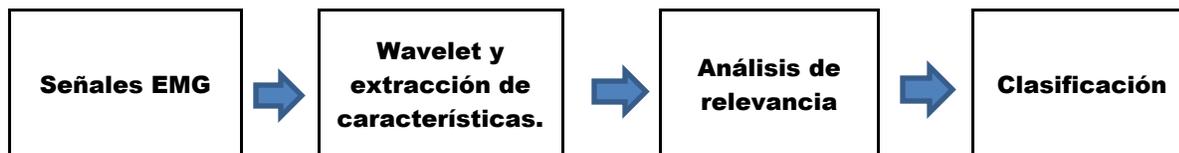
- Las grabaciones fueron hechas por encima del umbral del nivel de contracción voluntaria y constante, establecidos por procedimientos médicos.
- Se utilizó información visual y de audio para supervisar la calidad de la señal.
- Se utilizó un electrodo de aguja concéntrica estándar.
- Las señales EMG se registraron a partir de cinco lugares en el músculo en tres niveles de inserción (profundo, media, baja).
- Los filtros de paso alto y bajo del amplificador EMG se ajustaron a 2 Hz y 10 kHz paso alto y bajo del amplificador.
- De todos los conjuntos de datos se extrajeron 40 registros.

En total se contó con 395 registros del bíceps braquial pero con el fin de tener una muestra homogénea se extrajeron aleatoriamente 40 registros por cada clase y con ellos se conformó la matriz de señales EMG denominada  $\Omega$ .

## 3.2 Metodología propuesta

Con el fin de cumplir con el objetivo general de proponer una metodología de clasificación de señales de electromiografía mediante el análisis tiempo-frecuencia, orientada al diagnóstico de lesiones de plexo braquial en traumatismo cerrado, se planteó el siguiente análisis para la clasificación:

**Figura 7. Esquema general del procedimiento**



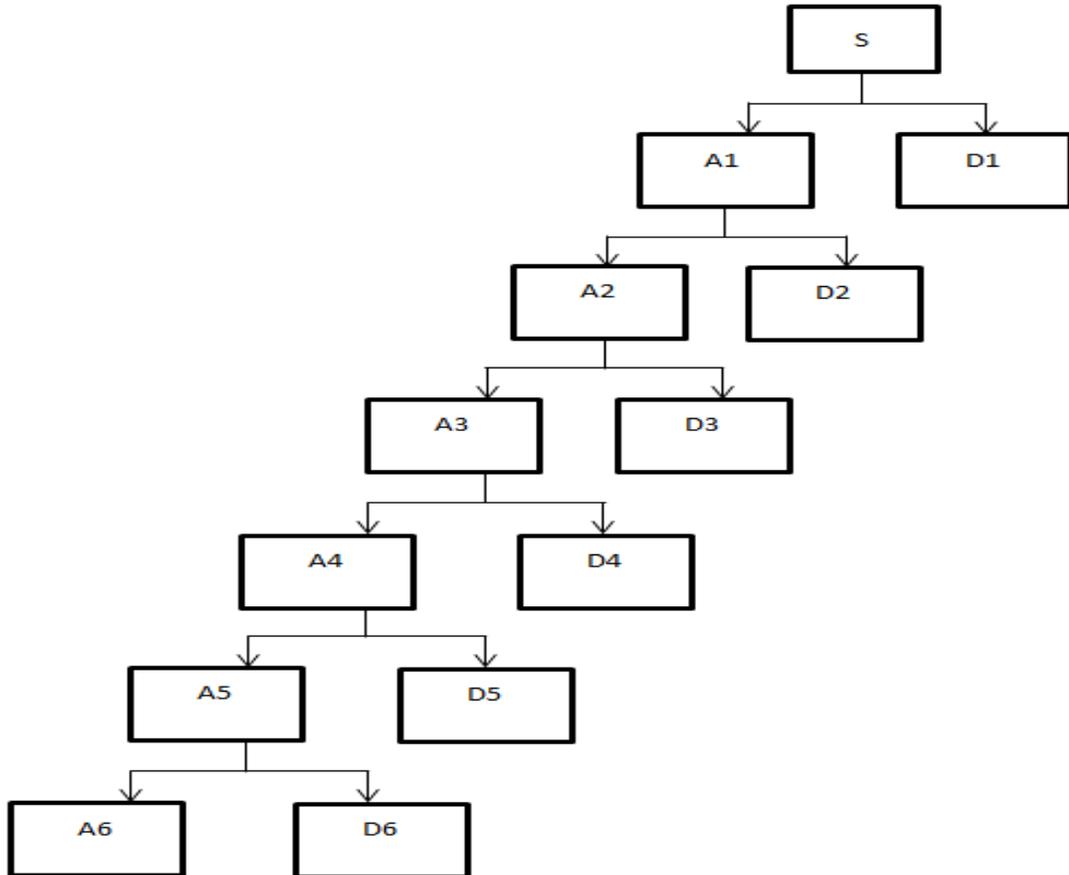
### 3.2.1 Señales EMG

La base de datos descrita en el numeral **3.1** que consta de 395 registros fue recortada a 120 registros (40 para cada clase), los cuales se seleccionaron aleatoriamente con el fin de tener una muestra homogénea con la que se conformó la matriz  $\Omega_{131072 \times 120}$  para su posterior descomposición.

### 3.2.2 Descomposición de las señales EMG por medio de la DWT y extracción de características

Para la descomposición de las señales EMG, se eligió la familia DB8 con seis niveles (ver **Figura 8**), expresados como niveles de detalle (D1,..., D6) y aproximación (A1,..., A6). Se utilizaron en total siete funciones que se dividieron en dos grupos: las funciones estadísticas ( $\mu$ ,  $\sigma$ ,  $\zeta^2$  y la  $g_2$ ) y las funciones de energía ( $E$ ,  $E_h$  y la  $E_t$ ). Estas funciones se definen en las ecuaciones 12 a 18 así:

Figura 8. Árbol DW8 con seis niveles de descomposición



- **Media aritmética ‘ $\mu$ ’:** es una medida de tendencia central y se define como el promedio de un conjunto de valores o su distribución, como se muestra en la Ecuación 12.

**Ecuación 12.** Media aritmética

$$\mu = \frac{1}{j} \sum_{i=1}^i Y_i$$

Donde  $i$  y  $j$  son constantes enteras y  $Y_i$  representa cada uno de los datos.

- **Desviación estándar ‘ $\sigma$ ’:** representa la variación de los datos en un conjunto con respecto a la media y se encuentra estrechamente ligada a la varianza como se ve en la Ecuación 13.

**Ecuación 13.** Desviación estándar

$$\sigma = \sqrt{\zeta^2}$$

Donde  $\zeta^2$  es la varianza.

- **Varianza** ' $\zeta^2$ ': es una medida de dispersión y muestra la variabilidad de una distribución con respecto a la media así:

**Ecuación 14.** Varianza

$$\zeta^2 = \frac{1}{j-1} \sum_{i=1}^j (Y_i - \mu)^2$$

Donde  $\mu$  es la media aritmética,  $i$  y  $j$  son constantes enteras y  $Y_i$  representa cada uno de los datos.

- **Curtosis** ' $g_2$ ': esta característica mide que tan concentrados o alejados se encuentran los datos de la media. Dicha medida, dada por la Ecuación 15, puede interpretarse de tres maneras distintas de acuerdo a su valor: si  $g_2$  es igual a 3 se dice que la distribución es mesocúrtica, si  $g_2$  es mayor que 3 es leptocúrtica y si  $g_2$  es menor a 3 es platicúrtica.

**Ecuación 15.** Curtosis

$$g_2 = \frac{\mu_4}{\sigma^4}$$

Donde,  $\mu_4$  es el 4º momento con respecto a la media y  $\sigma^4$  es la desviación estándar elevada a la 4.

- **Energía** ' $E$ ': es la representación cuadrática de los componentes principales. Este concepto es aplicado comúnmente en señales invariantes y variantes en el tiempo (Atlas y Fang, 1992) y se define como:

**Ecuación 16. Energía**

$$E = \sum_{i=1}^n x_i^2$$

Donde  $x$  es una señal y  $n$  su número de muestras.

- **Energía de Hilbert Shannon ‘ $E_h$ ’:** esta se define como la entropía de Shannon del cuadrado de la señal, y se calcula mediante la siguiente expresión según Liang, Lukkarimen, y Hartimo (1998) y Ahlstrom, Hult, Karlsson, Nylander y Dahlstrom (2006):

**Ecuación 17. Energía de Shannon**

$$E_h = -\frac{1}{M} \sum_{m=0}^{M-1} x[n-m]^2 \log(x[n-m]^2)$$

Donde  $x[n-m]$  es la amplitud de la señal y  $n-m$  es el número de muestras en el dominio del tiempo discreto.

- **Operador de Teager ‘ $E_t$ ’:** sirve para estimar la energía de una señal que oscila teniendo en cuenta tanto la amplitud como la frecuencia, ya que se necesita más energía para generar señales de mayor frecuencia. Así, las consideraciones energéticas para el caso de movimiento armónico simple, muestran que la energía requerida para generar una señal oscilatoria está dada por el cuadrado del producto de la amplitud de la señal y de su frecuencia (Kaiser, 1990). Al aplicar la ley de Newton de movimiento a una masa  $m$  suspendida por un resorte de constante  $k$  se obtiene la siguiente ecuación diferencial de segundo orden así:

**Ecuación 18. Operador de Teager**

$$\frac{d^2x}{dt^2} + \frac{k}{m}x = 0$$

Al calcular los rasgos ya descritos (funciones estadísticas y de energía) después de la descomposición Wavelet, se obtuvieron 49 características por paciente sobre el conjunto de coeficientes de la Wavelet (siete sub-bandas por siete características). Debido a la cantidad de información fue necesario determinar cuáles características aportaban mayor información para lo que se utilizó un análisis de relevancia.

### 3.2.3 Análisis de relevancia

Este análisis se realizó con el fin de determinar cuáles de las 49 características aportaban información más discriminante para la posterior clasificación de las señales EMG. Se utilizaron tres técnicas distintas para el análisis de relevancia descritas en 2.4, la primera de ellas fue **PCA** para la cual se definió como entrada la matriz de características  $X_{\xi}$  y como salida la matriz de características transformadas **Z**, ordenadas en vectores con la mayor varianza acumulada. Las siguientes técnicas fueron **ED** y **VE**, en ambos casos se utilizó la misma  $X_{\xi}$  como entrada y como salida se le asignó a cada  $\xi_i$  un peso, estos fueron ordenados de menor a mayor para el caso de **ED** debido a que las características de menor peso son las más relevantes para dicha técnica. Caso contrario sucedió con la **VE**, donde las  $\xi_i$  de mayor peso son las más relevantes y debido a la condición se reorganizó la matriz con este criterio.

### 3.2.4 Clasificación

Con el fin de validar la metodología propuesta, se realizó un procedimiento de clasificación utilizando el procedimiento de CV con 10-folds, cada fold contiene la misma cantidad de señales por clase. Los índices de clasificación son Porcentaje de acierto (Acc (%)), sensibilidad (Sen (%)) y especificidad (Sp (%)), cada uno de ellos definido respectivamente:

**Ecuación 19.** Índices de clasificación

$$Acc \% = \frac{100 N_C}{N_T}$$

$$Sen \% = \frac{100 N_{VP}}{(N_{VP} + N_{FN})}$$

$$Sp \% = \frac{100 N_{VN}}{(N_{VN} + N_{FP})}$$

Donde  $N_C$  es el número de patrones clasificados correctamente,  $N_T$  es el total de patrones utilizados para alimentar el clasificador,  $N_{VP}$  es el número de verdaderos positivos (clase objetivo clasificada en forma correcta),  $N_{FN}$  es el número de falsos negativos (clase objetivo clasificada como clase de referencia),  $N_{VN}$  es el número de verdaderos negativos (clase de referencia clasificada de forma correcta) y  $N_{FP}$  es el número de falsos positivos (clase de referencia clasificada de forma incorrecta).

La clasificación se realiza utilizando un clasificador de K-nn (definido en el numeral **2.5**) utilizando la distancia euclídea y  $K=5$  para todas las pruebas antes de realizar el ajuste del clasificador. Las pruebas de clasificación se pueden observar de manera detallada en el capítulo 4.

Adicionalmente se utilizó la matriz de confusión en el mejor esquema de clasificación, la cual es una herramienta de visualización empleada en el aprendizaje supervisado. Cada fila de la matriz representa el número de predicciones de cada clase, mientras cada columna representa a las instancias en la clase real.

Tabla 1. Matriz de confusión

	REALIDAD	
ESTIMACIÓN	Enfermo	Sano
Positivo	$N_{VP}$	$N_{FP}$
Negativo	$N_{FN}$	$N_{VN}$

## 4. Resultados y discusión

Para todas las pruebas realizadas se tomó de la base de datos 120 registros de 395 disponibles, los cuales se seleccionaron aleatoriamente con el fin de tener una muestra homogénea (misma cantidad de muestras por clase), en este caso 40 por cada clase para obtener una matriz de señales EMG  $\Omega_{131072 \times 120}$ .

### 4.1 Prueba con normalización

Para comprender la dinámica del sistema y establecer un punto de partida, se realizó una primera prueba de clasificación sin normalizar las señales, luego se aplicó normalización estadística (Nes) y por último una normalización geométrica (Nge) a la base de datos. Estos datos se almacenaron en una matriz denominada  $\Omega$ . Posteriormente se aplicó una descomposición multinivel con la DWT y seis niveles de descomposición utilizando la familia la Daubechies (DB4), para hacer contraste con lo hallado en la literatura dicha por Subasi (2013), Subasi (2012) y Hossen (2010). Después de realizar la descomposición obteniendo los coeficientes Wavelet discretos, se les calculó el valor absoluto a cada nivel (D1, D2, D3, D4, D5, D6 y A6) y posteriormente se realizó un análisis para comprender la dinámica del sistema y obtener de éste características importantes para la clasificación.

Dichas  $\xi$  se agruparon en la matriz de características  $X_\xi$  después de calcularles la  $\mu$ ,  $\sigma$ , la  $E$ .

Para las pruebas de la 4.1 a la 4.4 en clasificación se utilizó el K-nn con  $K=5$  de acuerdo a lo sugerido en la literatura (Subasi, 2013), (Christodoulou et al. 2012). En la prueba 4.5 se realizó el ajuste del clasificador para encontrar el valor óptimo de  $K$ . Este ajuste se realizó variando el valor de  $K$ , en cada ejecución del

algoritmo de cross validación. El valor final fue el que tuvo mayor acierto en clasificación el cual, se aplicó para las pruebas sucesivas a dicho ajuste. Los parámetros obtenidos de la clasificación Acc (%), sensibilidad Sen (%) y Sp (%) fueron almacenados en una matriz **Z**, después de normalizar los datos, de acuerdo con las ecuaciones 20 y 21.

**Ecuación 20.** Normalización estadística

$$Nes = \frac{(\Omega - \sigma(\Omega))}{(\sigma(\Omega))}$$

Donde  $\Omega$  es la matriz de señales EMG y  $\sigma$  es la desviación estándar.

**Ecuación 191.** Normalización Geométrica

$$Nge = \frac{(\Omega - \mu(\Omega))}{(abs(max[\Omega_{max} - \mu \Omega, \mu \Omega - \Omega_{min}])}$$

Donde  $\Omega$  es la matriz de señales EMG y  $\mu$  la media aritmética.

En la **Tabla 2** se muestran los resultados obtenidos de la clasificación utilizando la base de datos sin normalización para determinar si existía información en la amplitud de la señal. Mientras en la **Tabla 3**, se muestran los resultados obtenidos de la clasificación utilizando la base de datos con normalización estadística, y en la **Tabla 4** se muestran los resultados obtenidos de la clasificación utilizando la base de datos con normalización geométrica.

**Tabla 2. Clasificación sin normalizar  $\Omega$ .**

Clase	Acc (%)	Sen(%)	Sp (%)
ALS	68.53 ± 13.53	69.04 ± 23.53	82.75 ± 12.59
MIO		75.17 ± 20.48	61.50 ± 22.67
NOR		94.61 ± 7.58	75.60 ± 15.25

**Tabla 3. Clasificación con normalización estadística  $\Omega$ .**

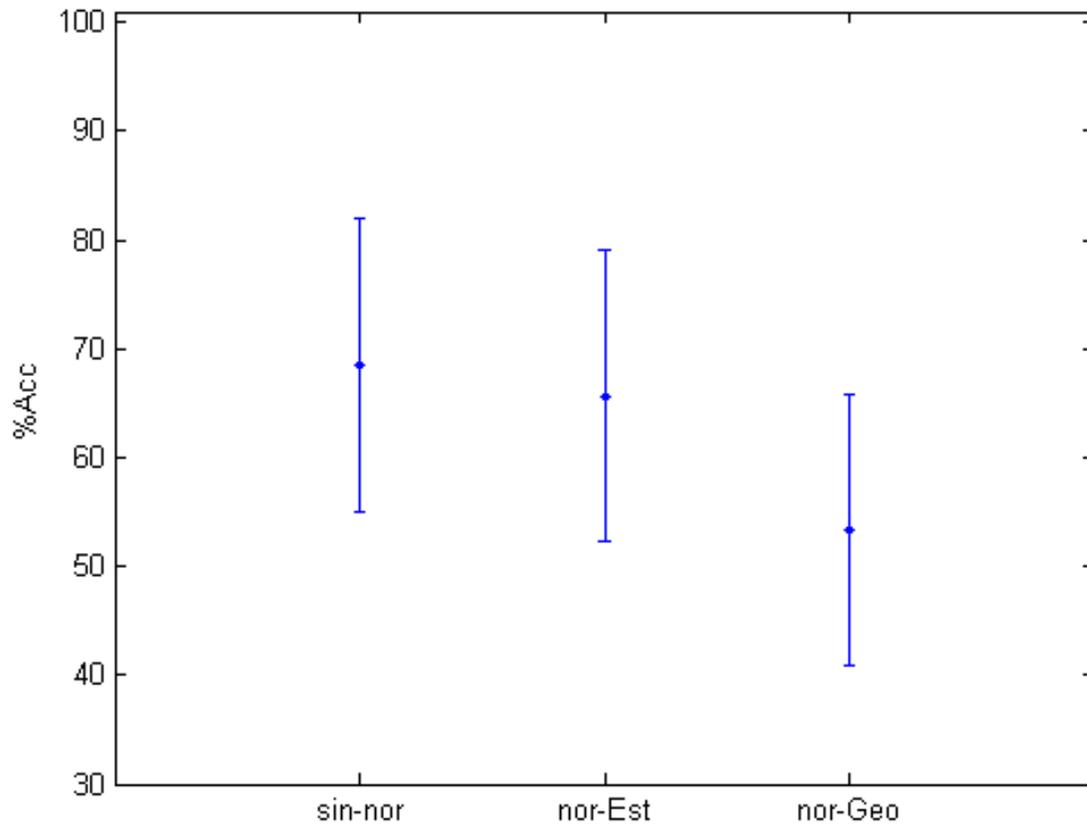
Clase	Acc (%)	Sen (%)	Sp (%)
ALS	65.68 ± 13.41	61.08 ± 23.63	83.96 ± 13.31
MIO		71.47 ± 21.30	87.18 ± 11.33
NOR		64.37 ± 23.43	77.46 ± 12.93

**Tabla 4. Clasificación con normalización geométrica de  $\Omega$** 

Clase	Acc (%)	Sen (%)	Sp (%)
ALS	53.43 ± 12.44	35.71 ± 23.31	83.56 ± 12.44
MIO		64.35 ± 22.31	83.02 ± 13.00
NOR		59.37 ± 23.30	63.60 ± 16.32

En la **Figura 9**, se pueden observar las barras de error que indican los intervalos de confianza de los datos en forma descendente de los índices de Acc (%). En la primera barra se encuentran los índices de clasificación sin normalizar  $\Omega$ , en la segunda barra se observan los índices de la clasificación con normalización estadística y en la tercera barra se referencian los índices de la clasificación con la normalización geométrica.

El Acc (%) más alto se encontró cuando no se normalizaron las señales EMG, de lo cual se puede intuir que la amplitud de la señal puede tener información, por lo tanto, basado en este análisis se decidió que para las pruebas siguientes no se normalizarían las señales debido a que con la realización de este procedimiento se perdió información importante presente en los picos más altos, logrando una reducción en los indicadores de clasificación.

**Figura 9. Prueba de clasificación con distintas normalizaciones**

De acuerdo a la evidencia encontrada por Subasi (2013), se realizó una segunda prueba incluyendo otras características estadísticas y de energía. Además de normalizar la matriz de características y no la matriz de las señales EMG.

## **4.2 Prueba con combinación de características estadísticas y de energía normalizadas**

Para esta prueba se usó la matriz  $\Omega$  de la base de datos sin normalización; la descomposición se realizó por medio de la transformada DWT utilizando la familia DB4 con seis niveles de descomposición; para la caracterización se utilizaron

rasgos estadísticos y de energía. Las  $\xi$  estadísticas que se incluyeron fueron, la media  $\mu$ ,  $\sigma$ ,  $\zeta^2$  y la  $g_2$ . Las  $\xi$  de energía fueron  $E$ , energía de Hilbert-Shannon  $E_h$  y el operador de Teager  $E_t$  para un total de 49 características almacenadas en la matriz  $X_\xi$  las cuales fueron normalizadas y para la clasificación se utilizó el K-nn con  $K=5$  vecinos.

Una primera prueba consistió en clasificar las señales EMG con todas las características normalizadas, **Tabla 5**.

**Tabla 5. Clasificación con todas las características normalizadas.**

Clase	Acc (%)	Sen (%)	Sp (%)
ALS	71.36 ± 8.51	73.13 ± 14.88	90.38 ± 6.38
MIO		83.40 ± 12.45	84.55 ± 8.67
NOR		57.3250 ± 17.1134	82.04 ± 8.98

En la **Tabla 6**, se puede ver los datos obtenidos de la clasificación sólo con características estadísticas.

**Tabla 6. Clasificación con características estadísticas normalizadas.**

Clase	Acc (%)	Sen (%)	Sp (%)
ALS	69.30 ± 8.89	68.25 ± 16.98	89.71 ± 6.61
MIO		80.24 ± 13.23	84.9017 ± 8.70
NOR		59.05 ± 17.26	79.46 ± 9.59

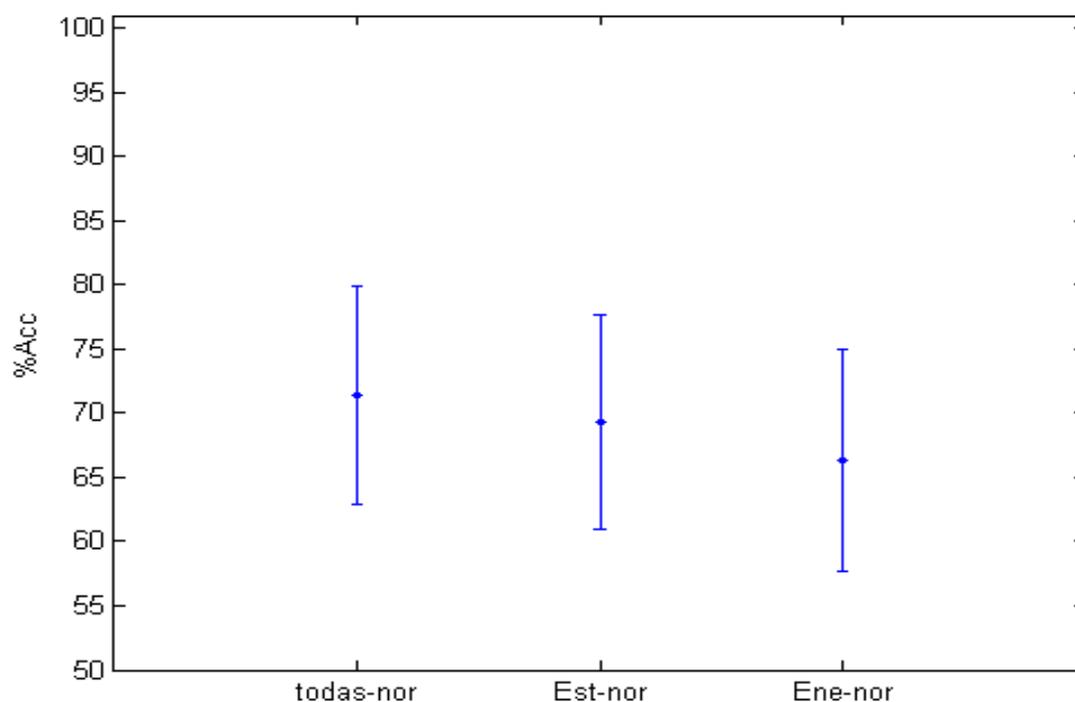
En la siguiente prueba se realizó la clasificación sólo utilizando las características de energía, ver **Tabla 7**.

**Tabla 7. Clasificación con características de energía normalizadas.**

Clase	Acc (%)	Sen (%)	Sp (%)
<b>ALS</b>	66.34 ± 8.70	68.79 ± 16.20	87.59 ± 7.77
<b>MIO</b>		79.29 ± 13.3	81.71 ± 9.03
<b>NOR</b>		50.77 ± 16.19	80.13 ± 9.56

En la **Figura 10**, se realizó la comparación de las barras de error, encontrando que el intervalo de más confianza fue cuando se utilizaron todas las características y el intervalo de menos confianza cuando se utilizaron solo los rasgos de energía cómo se aprecia en la gráfica.

**Figura 10. Error prueba de clasificación con combinación de características.**



De lo anterior se puede decir que la combinación de las características estadísticas con las características de energía mejora los índices del clasificador.

### 4.3 Prueba bi-clase con combinación de características estadísticas y de energía

De acuerdo con la tendencia observada de variabilidad en los índices de clasificación se implementó una nueva prueba. Esta consistió en una clasificación bi-clase donde se selecciona una clase como objetivo y las restantes como comparación, esto con el fin de determinar el comportamiento de cada clase frente a las otras y así comprender con mayor claridad la dinámica del sistema y de este modo poder aumentar el porcentaje de acierto o definir otra estrategia de clasificación. Dichas pruebas pueden observarse en la información consignada de la **Tabla 8** a la **Tabla 15**.

En la **Tabla 8**, se muestran los resultados obtenidos con las clases ALS y MIO con todas las características estadísticas y de energía.

**Tabla 8. Prueba ALS y MIO con todas las características normalizadas.**

Clase	Acc (%)	Sen (%)	Sp (%)
ALS	93.39 ± 5.52	99.47 ± 3.07	87.30 ± 10.56
MIO		87.30 ± 10.56	99.47 ± 3.07

En la **Tabla 9**, se muestra los resultados de las clases ALS y MIO solo con las características estadísticas y en la **Tabla 10**, se observan los resultados de la clase ALS y MIO con características de energía.

**Tabla 9. Prueba ALS y MIO con características estadísticas normalizadas.**

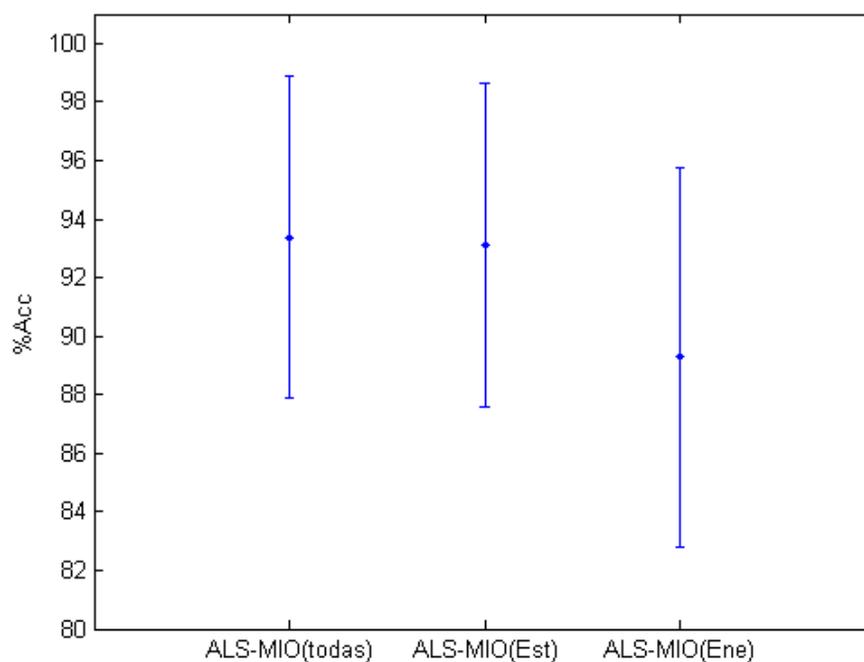
Clase	Acc (%)	Sen (%)	Sp (%)
ALS	93.10 ± 5.74	99.02 ± 3.35	87.17 ± 11.28
MIO		87.17 ± 11.28	99.02 ± 3.35

**Tabla 10. Prueba ALS y MIO con características de energía normalizadas.**

Clase	Acc (%)	Sen (%)	Sp (%)
ALS	89.29 ± 6.467	91.35 ± 9.41	87.2250 ± 10.77
MIO		87.22 ± 10.77	91.35 ± 9.41

Para comprender con mayor claridad los índices obtenidos, se realizó un análisis gráfico con ayuda de la **Figura 11**.

**Figura 11. Error prueba bi-clase ALS y MIO con combinación de características normalizadas.**



Se observa que el intervalo de mayor confianza para las clases ALS y MIO, fue obtenido cuando se utilizaron todas las características para la clasificación y el menor intervalo fue para los rasgos de energía.

En la **Tabla 11**, se muestran los indicadores para la clasificación de las clases ALS y NOR con todas las características estadísticas y de energía.

**Tabla 11. Prueba ALS y NOR con todas las características normalizadas.**

Clase	Acc (%)	Sen (%)	Sp (%)
ALS	93.62 ± 5.69	99.57 ± 2.53	87.67 ± 11.17
NOR		87.67 ± 11.18	99.57 ± 2.53

En la **Tabla 12**, se muestran los indicadores para la clasificación de las clases ALS y NOR con características estadísticas.

**Tabla 12. Prueba ALS y NOR con características estadísticas normalizadas.**

Clase	Acc (%)	Sen (%)	Sp (%)
ALS	93.20 ± 5.864	99.20 ± 3.06	87.20 ± 11.38
NOR		87.20 ± 11.38	99.20 ± 3.06

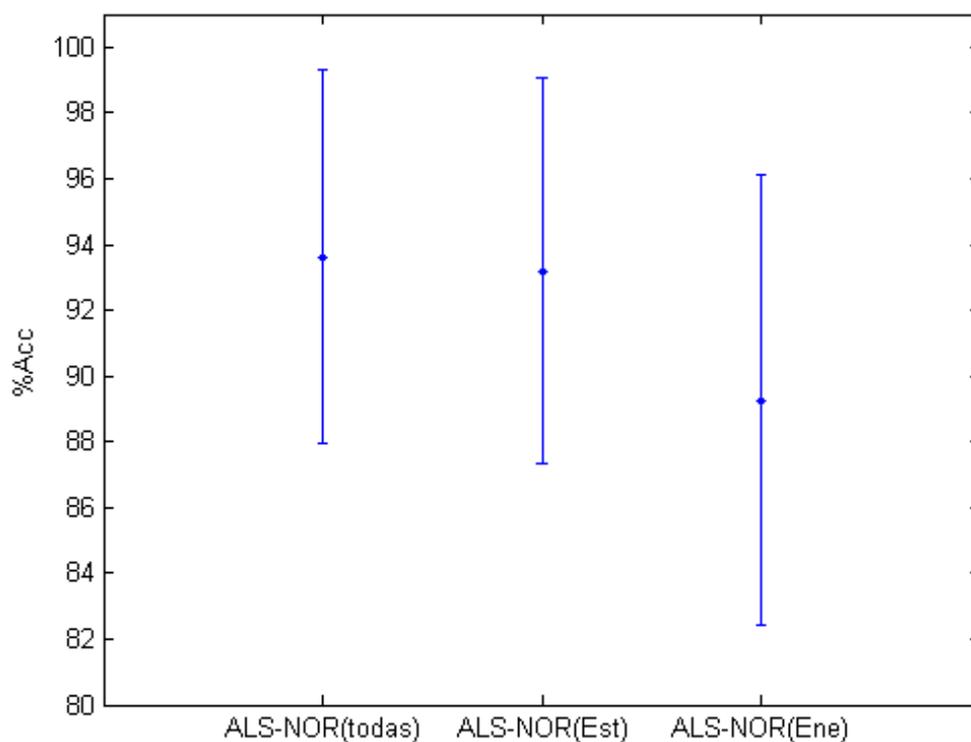
En la **Tabla 13**, se muestran los indicadores para la clasificación de las clases ALS y NOR con todas las características de energía.

**Tabla 13. Prueba ALS y NOR con características de energía normalizadas.**

Clase	Acc (%)	Sen (%)	Sp (%)
ALS	89.27 ± 6.87	91.00 ± 9.73	87.55 ± 11.08
NOR		87.55 ± 11.08	91.00 ± 9.74

En la Figura 12 se pueden observar los intervalos de confianza y las desviaciones estándar alrededor de las medias para las clases ALS y NOR.

**Figura 12. Error prueba bi-clase ALS y NOR con combinación de características normalizadas.**



Por último se realizó la prueba bi-clase con MIO y NOR utilizando el mismo procedimiento al combinar los dos grupos de características como se observa en la **Tabla 14** a la **Tabla 16**.

**Tabla 14. Prueba MIO y NOR con todas las características normalizadas.**

Clase	Acc (%)	Sen (%)	Sp (%)
MIO	93.55 ± 5.68	99.60 ± 2.47	87.50 ± 11.30
NOR		87.50 ± 11.31	99.60 ± 2.47

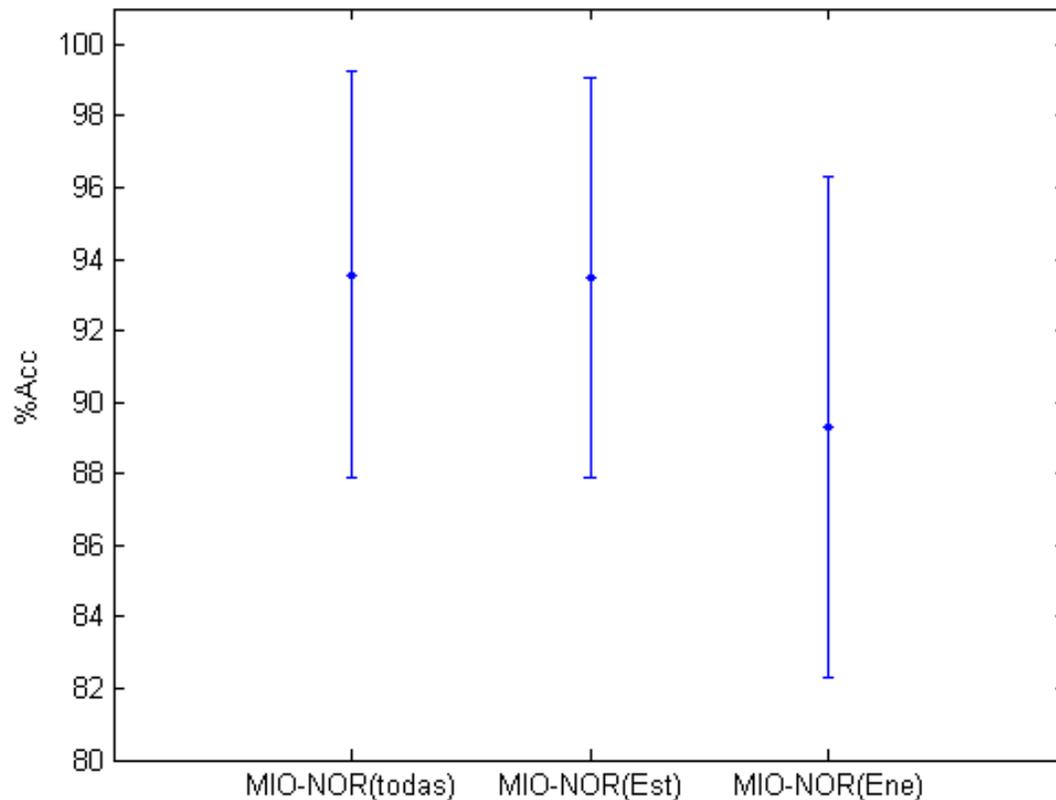
**Tabla 15. Prueba MIO y NOR con características estadísticas normalizadas.**

Clase	Acc (%)	Sen (%)	Sp (%)
MIO	93.45 ± 5.59	99.17 ± 3.11	87.72 ± 10.92
NOR		87.72 ± 10.92	99.17 ± 3.11

**Tabla 16. Prueba MIO y NOR con características de energía normalizadas.**

Clase	Acc (%)	Sen (%)	Sp (%)
MIO	89.30 ± 6.98	91.45 ± 9.02	87.15 ± 11.49
NOR		87.15 ± 11.49	91.45 ± 9.02

**Figura 13. Error prueba bi-clase MIO y NOR con combinación de características normalizadas**



El intervalo de mayor confianza lo tiene la prueba realizada para las clases MIO y NOR observado en la **Figura 13** con todas las características y continuó mostrando que el de menor índice de Acc es cuando solo se clasificó con los rasgos de energía. Por otra parte, de las **Tablas 8, 11, 14** se puede afirmar que, las clases son perfectamente diferenciables entre ellas, los mejores intervalos de confianza se obtuvieron cuando se utilizaron los dos grupos de características (estadísticas y de energía), la desviación estándar disminuyó también con esta combinación. Por otra parte, con esta prueba se pudo corroborar que la metodología de descomposición utilizando la DB4 y clasificando con  $K=5$ , fue adecuada para el tipo de señales que se estaban empleando.

#### 4.4 Prueba con los valores absolutos de los coeficientes Wavelet.

Se realizó un estudio más profundo del estado del arte y se encontró que algunos autores como Subasi (2012) antes de realizar la clasificación, calculaban los valores absolutos de los coeficientes Wavelet. Con esto se implementó una nueva prueba que consistió en utilizar las tres clases ALS, MIO y NOR con combinación de características estadísticas y de energía normalizadas, pero con la diferencia que se obtuvieron los valores absolutos de los coeficientes encontrados al realizar la transformación tiempo-frecuencia empleando la DB4. Este experimento se dividió en dos pruebas, una primera clasificación sin normalizar las características y otra normalizándolas tal como se muestra en la **Tabla 17** y **Tabla 18**.

**Tabla 17. Clasificación con valores absolutos de los coeficientes sin normalizar.**

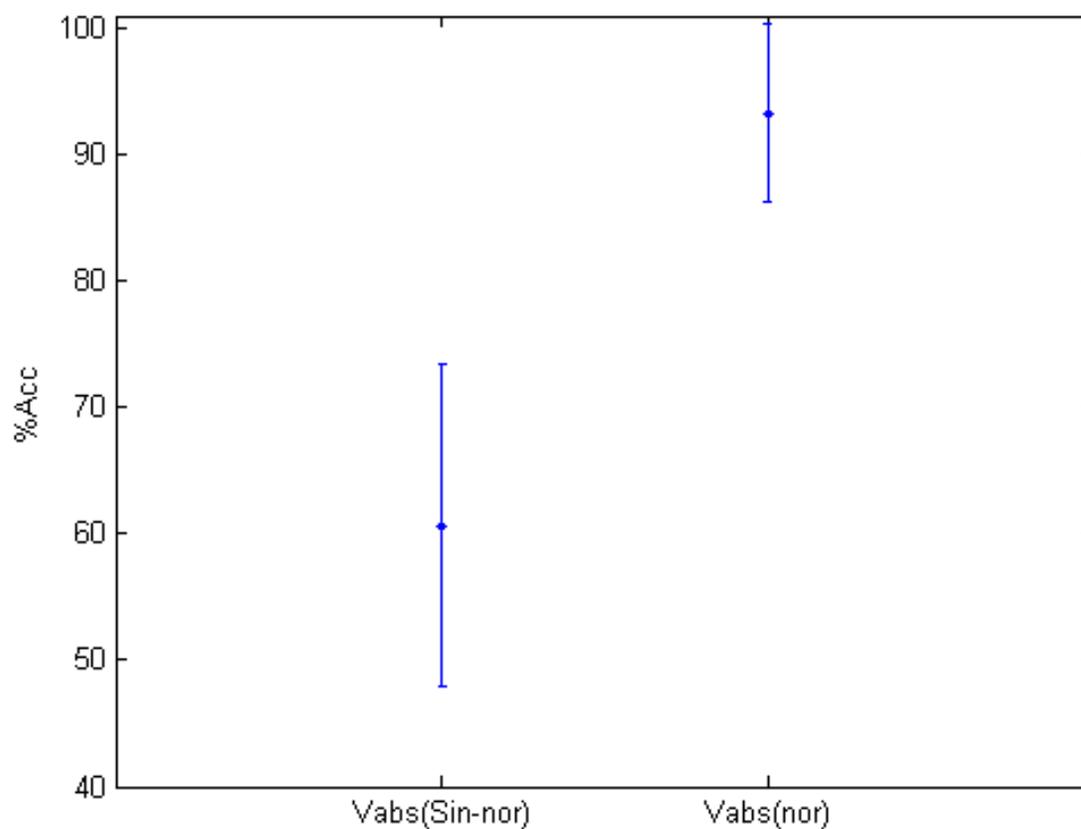
Clase	Acc (%)	Sen (%)	Sp (%)
ALS	60.65 ± 12.78	58.80 ± 23.14	86.62 ± 11.06
MIO		71.52 ± 21.54	86.80 ± 11.41
NOR		51.62 ± 25.17	67.55 ± 15.37

**Tabla 18. Clasificación con valores absolutos de los coeficientes normalizados.**

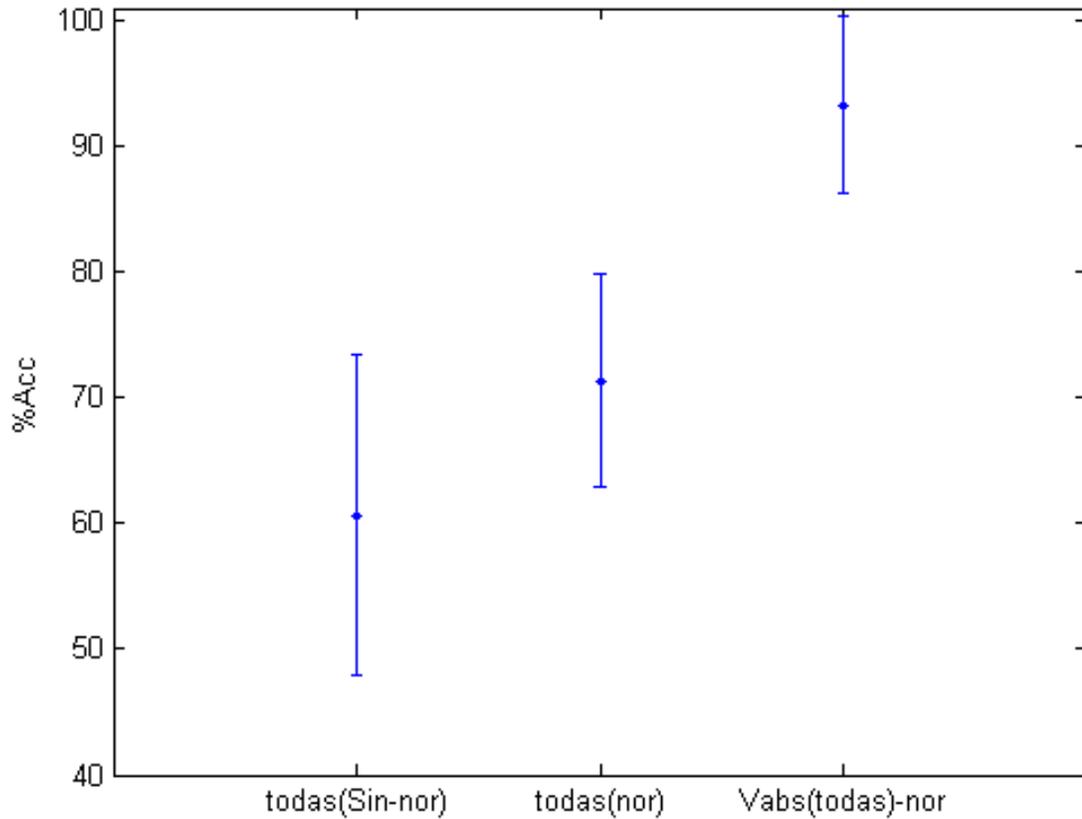
Clase	Acc (%)	Sen (%)	Sp (%)
ALS	93.32 ± 7.04	84.42 ± 18.08	99.73 ± 1.79
MIO		99.37 ± 3.90	91.78 ± 9.76
NOR		96.17 ± 10.83	98.46 ± 4.22

Los resultados mostrados en las **Tablas 17 y 18**, se confrontaron en la Figura 14, donde se puede observar que los mejores resultados obtenidos fue cuando se clasificó con las características estadísticas y de energía **Tabla 18**, encontrando un incremento del 32.62% de Acc (%) y una disminución de la desviación estándar en un  $\pm 5.74\%$  con respecto a los datos registrados en la **Tabla 17**.

**Figura 14. Error clasificación con los valores absolutos.**



Se realizó una comparación entre las **pruebas 3.1, 3.2 y 3.3** para determinar en cuál de ellas se obtuvieron mejores resultados. Esta comparación se muestra en la Figura 15.

**Figura 15. Error mejores resultados de las pruebas.**

El primer intervalo de confianza de la **Figura 15**, corresponde a la prueba con normalización, en él se pueden observar los resultados de la clasificación sin normalizar la base de datos, dichos resultados son bajos con respecto a las otras pruebas en cuanto a Acc (%). En la segunda barra se referenció la prueba de los valores absolutos de los coeficientes Wavelet, en la que se observa un porcentaje de Acc (%) más alto que el anterior y una desviación estándar más baja. Por último, la tercer barra corresponde a la prueba con ajuste de la Wavelet madre, en la que los índices son considerablemente mejores, ya que se pasó de un porcentaje de Acc (%) del 68.5350 al 93.32 y una desviación estándar del  $\pm 13.5301\%$  al  $\pm 7.04\%$ .

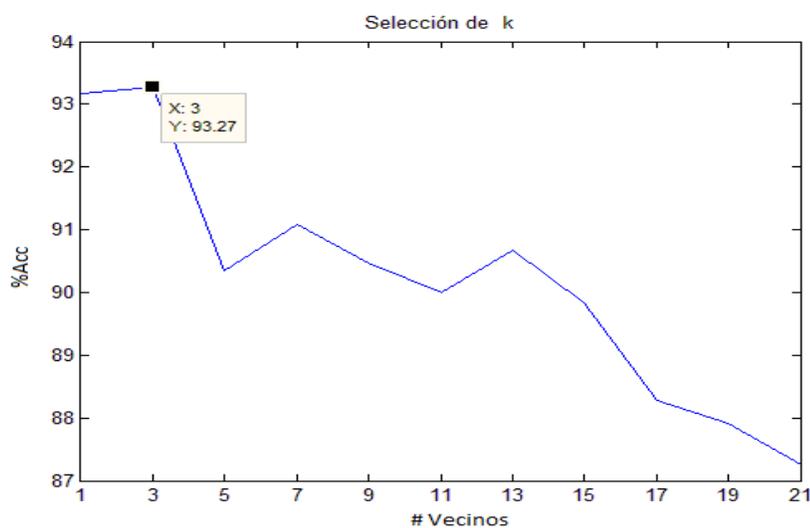
De lo anterior se puede concluir que:

- Al realizar la caracterización se deben calcular los valores absolutos de los coeficientes Wavelet, ya que se evidenció una mejora en los índices de clasificación.
- Con un incremento en el índice de Acc (%) del 24.78 % y una disminución de la desviación estándar del  $\pm 6.49\%$  entre el tercer intervalo de confianza y el primero, se puede afirmar que, la metodología descrita en la prueba de optimización de la Wavelet madre es la más adecuada hasta el momento, para dar un diagnóstico concluyente de una Lesión de Plexo Braquial.

## 4.5 Ajuste del clasificador

Hasta ahora se ha clasificado utilizando los cinco vecinos más cercanos  $K=5$ . Con el fin de obtener un valor más adecuado de  $K$  se realizaron varias pruebas de clasificación variando su valor desde 1 hasta 21, solo en valores impares como se muestra en la **Figura 16**.

**Figura 16. Valor óptimo de 'k'.**



De la **Figura 16**, se puede observar que con  $K=3$  se alcanzó el porcentaje más alto de clasificación, el cual fue de 93.27% en cuanto a Acc (%) se refiere.

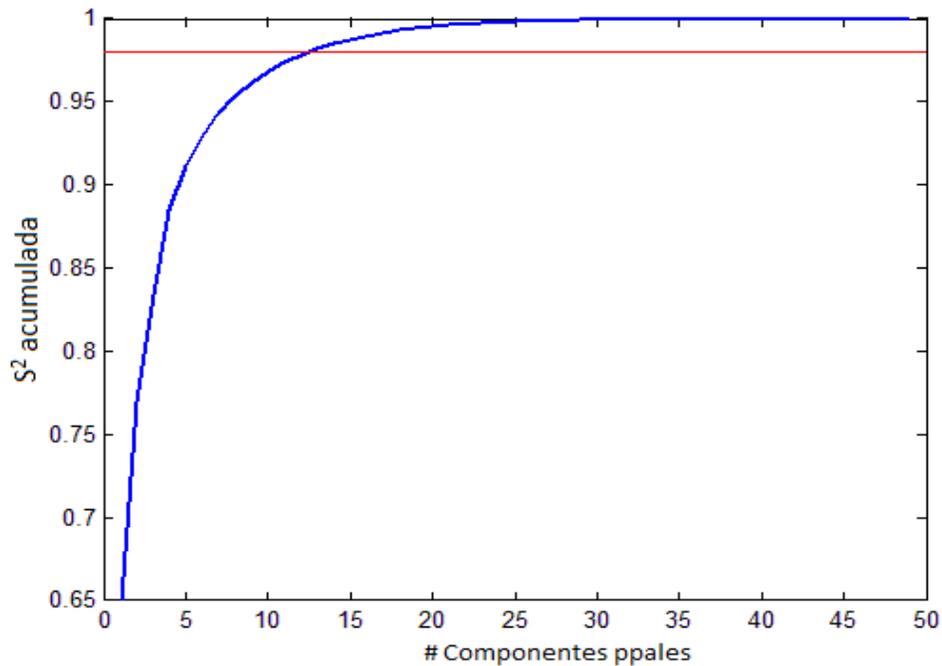
## 4.6 Selección de características

Con el fin de determinar cuáles características eran más relevantes para esta investigación, se realizó una selección de estas utilizando PCA, ED y V.E.

### 4.6.1 Análisis de Componentes Principales.

Cuando se aplicó PCA a la matriz  $X_{\xi}$  se encontró que trece vectores aportaban más del 98% de la variabilidad de los datos, como se observa en la **Figura 17**.

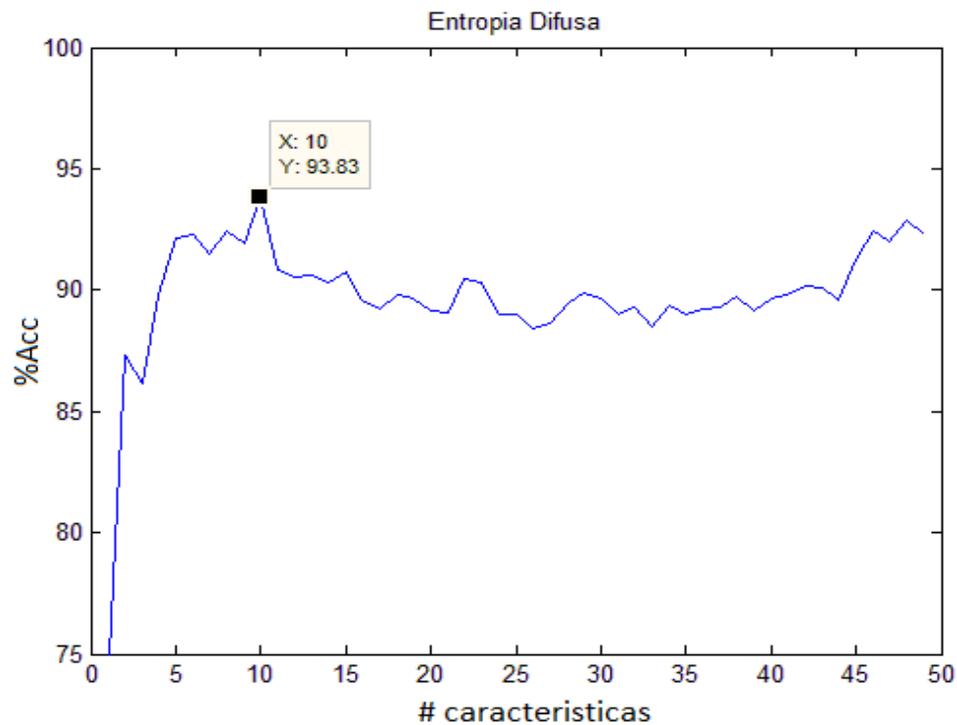
**Figura 17. Análisis de Componentes Principales.**



### 4.6.2 Selección con Entropía Difusa

Se aplicó el algoritmo de entropía difusa sobre las características para determinar cuáles eran las más relevantes, a continuación en la **Figura 18**.

**Figura 18. Selección de características más relevantes con ED**

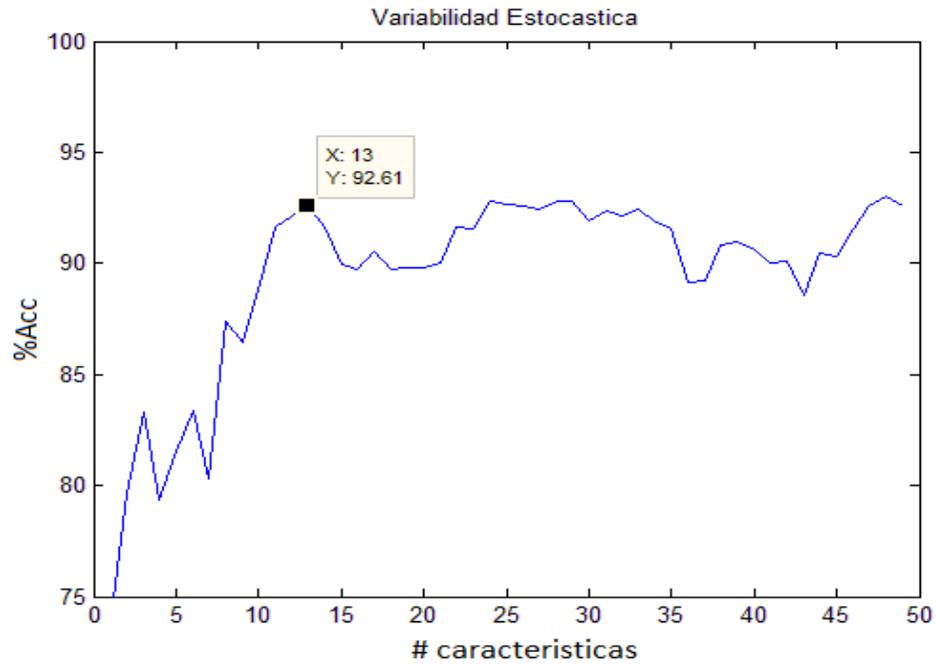


Con este algoritmo se encontró que con las primeras 10 características se logra un Acc (%) del 93.83%. También se pudo determinar cuáles fueron las características más relevantes y en qué nivel de descomposición de la DB4 se encontraban así:  $\mu D1$ ,  $\mu D5$ , EhD5, EtA6, EhA6, EhD6,  $\mu D6$ , EhD4, ED5, ED1.

### 4.6.3 Selección con Variabilidad Estocástica

Se aplicó el algoritmo de variabilidad estocástica sobre las características para determinar cuáles eran las más relevantes, como se observa en la **Figura 19**.

**Figura 19. Selección de características más relevantes con VE.**



El algoritmo determinó las siguientes características como las más relevantes:  $\mu D1$ ,  $EhD6$ ,  $EtD6$ ,  $\mu D2$ ,  $EhD5$ ,  $\mu D3$ ,  $ED6$ ,  $\mu D4$ ,  $EhD4$ ,  $EhA6$ ,  $\mu D5$ ,  $ED3$ ,  $\mu D6$ .

#### 4.6.4 Comparación de los resultados obtenidos con los algoritmos de VE y ED

En la **Tabla 19**, se relacionan los resultados obtenidos con ambos algoritmos de selección.

**Tabla 19. Características idénticas obtenidas con ED y VE.**

Entropía Difusa	Variabilidad Estocástica
$\mu D1$	$\mu D1$
$\mu D5$	$\mu D5$
$\mu D6$	$\mu D6$
$EhD4$	$EhD4$
$EhD5$	$EhD5$
$EhD6$	$EhD6$

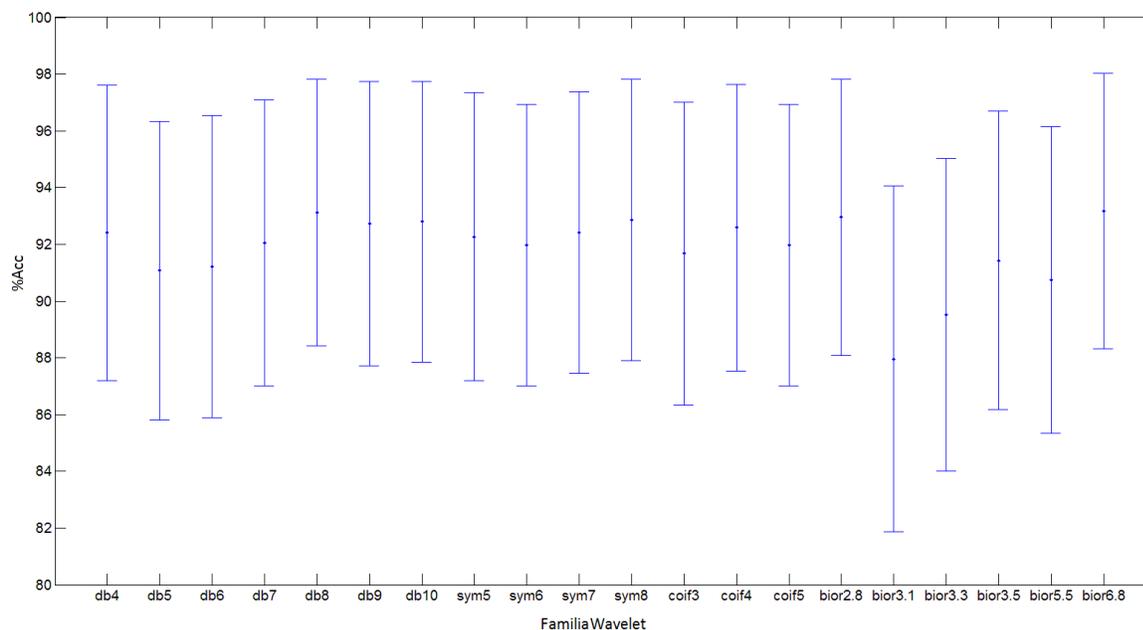
De igual manera, en la **Tabla 19** se puede observar que hubo concordancia en seis características, de igual manera se observa que la mayoría de las características seleccionadas mediante el análisis de relevancia están en las bandas de frecuencia más altas representados en los D5 y D6.

## 4.7 Ajuste de la Wavelet madre

En la literatura encontrada se reportó que los mejores resultados para electromiografía se obtuvieron utilizando la familia Daubechies 4 (Subasi, 2013). Con el fin de comprobar esos experimentos se realizaron varias pruebas de clasificación con distintas familias Wavelet y con seis niveles de descomposición para encontrar cuál de ellas era la más apropiada.

Para esta prueba se utilizaron las familias más utilizadas fueron la Daubechies (4, 5, 6, 7, 8, 9 y 10), Symlet (3, 4 y 5) y la Biorthogonal (2.8, 3.1, 3.3, 3.5, 5.5 y 6.8) como se evidencia en la **Figura 20**.

**Figura 20. Ajuste de la Wavelet madre.**



Esta prueba reveló que si bien las diferencias estadísticas no fueron significativas entre estas familias, aquellas que tienen la media de clasificación más alta y la desviación estándar más pequeña fueron las familias Daubechies 8 y Biortogonal 6.8.

## 4.8 Mejor esquema de clasificación

Teniendo en cuenta la prueba con los valores absolutos de los coeficientes de Wavelet, ajuste del clasificador, selección de características y el ajuste de la Wavelet madre, se realizó una nueva clasificación de señales EMG, utilizando el siguiente esquema:

- Descomposición Wavelet con la DB8.
- Extracción de características de los valores absolutos de los coeficientes Wavelet, con características estadísticas y de energía.
- Selección de Características con ED.
- Clasificación con K-nn utilizando  $K=3$ .

Los resultados de este esquema de clasificación se pueden observar en la **Tabla 20**.

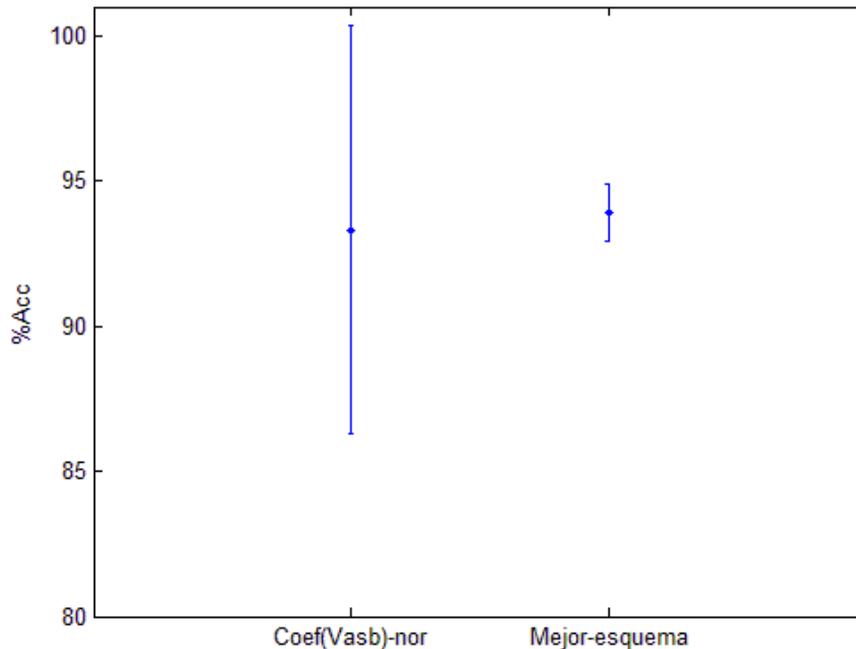
**Tabla 20. Mejores índices de clasificación.**

Clase	Acc (%)	Sen (%)	Sp (%)
ALS	93.91 ± 0.99	87.74 ± 2.05	98.63 ± 0.61
MIO		97.14 ± 1.30	92.32 ± 1.42
NOR		96.85 ± 2.07	99.91 ± 0.33

De acuerdo con los resultados obtenidos con este esquema de clasificación, **Tabla 20**, se realizó una comparación con los obtenidos en la prueba que vinculó

los valores absolutos de los coeficientes normalizados, **Tabla 18**, tal como se ve en la **Figura 21**.

**Figura 21. Comparación de Acc (%), pruebas 3.4 y 3.8.**



En la **Figura 21**, se puede observar que la primera barra corresponde a la prueba 3.4, “Prueba con los valores absolutos de los coeficientes Wavelet.”, en la que se obtuvo un  $\text{Acc} (\%) = 93.32\%$  y una  $\sigma = \pm 7.04\%$ . La segunda barra corresponde a la prueba 3.8, “Mejor esquema de clasificación”, donde se encontró un  $\text{Acc} (\%) = 93.91\%$  y una  $\sigma = \pm 0.99\%$ . Según estas dos pruebas, el  $\text{Acc} (\%)$  se incrementó en un  $0.59\%$  y la desviación estándar disminuyó en un  $\pm 6.05\%$ .

Con estos cambios en los indicadores, se puede concluir que:

- Con el esquema de clasificación propuesto sí se mejoraron los índices de clasificación.
- Se pudo clasificar una lesión de plexo braquial con un intervalo de confianza del  $93.91\%$  y una  $\sigma = \pm 0.99\%$ .

Adicionalmente, se utilizó la matriz de confusión para determinar la confusión entre clases

**Tabla 21. Matriz de confusión para mejores índices de clasificación.**

		REALIDAD		
		ALS	MIO	NOR
ESTIMACIÓN	ALS	86.61	3.87	0
	MIO	13.39	96.13	2.68
	NOR	0	0	97.32

En la **Tabla 21** se puede observar como la clase **NOR** es la que mejor índice de clasificación presenta, la clase **ALS** se confunde con la **MIO** en un gran porcentaje, pero no con la **NOR**, y pasa lo mismo con la clase **MIO**. Esto quiere decir que identifica bien a los enfermos aunque se equivoca entre las enfermedades en un 13.39%, mientras que si es normal es poco probable que esté enfermo.

## 4.9 Discusiones

Con los resultados obtenidos mediante la DWT para la caracterización de las señales electrográficas mediante la familia Daubechies 8, con seis niveles de descomposición, aplicando extracción de características de los valores absolutos de los coeficientes Wavelet (en donde se incluyeron las características estadísticas y de energía), realizando selección de características con Entropía Difusa y efectuando un análisis de componentes principales, se evidenció que con el clasificador K-nn ajustado a  $K=3$  el porcentaje de clasificación fue el más alto frente a las distintas pruebas realizadas y con un intervalo de confianza del 93.91% y una  $\sigma = \pm 0.99\%$  se pudo clasificar una lesión de plexo braquial. Los valores de especificidad y sensibilidad arrojados de las pruebas realizadas anteriormente demuestran la validez de la metodología propuesta para extraer y

seleccionar las características que permitieron identificar dos tipos de patologías. Sin embargo, técnicas como las SVM podrían mejorar el intervalo de confianza. Es de mencionar que las señales EMG utilizadas se encontraban pre-procesadas, por lo que el sistema no trabaja en tiempo real.

Se efectuó un ajuste del clasificador debido a que en la literatura encontrada, algunos autores como Subasi (2013), Christodoulou et al. (2012) utilizaban  $K=5$ . Dicho ajuste arrojó que el número adecuado de vecinos para proponer una metodología de clasificación de señales de electromiografía mediante el análisis tiempo-frecuencia, orientada al diagnóstico de lesiones de plexo braquial en traumatismo cerrado fue con  $K=3$ .

Las señales electromiográficas utilizadas como insumo para la metodología propuesta no se deben normalizar antes de ser descompuestas con la DWT, debido a que se intuye que en la amplitud de la señal hay información. Se llegó a esta conclusión debido a que en distintas pruebas se aplicó dos tipos de normalización y en todos los casos los porcentajes de Acc (%) disminuyeron, sin embargo, se puede repetir este procedimiento en señales sin pre-procesamiento y validar el funcionamiento.

El algoritmo de entropía difusa y de variabilidad estocástica por sus rasgos particulares permitió seleccionar las características más relevantes del conjunto de datos generado por la extracción y reducir su espacio dimensional de 49 características a 10 con ED, originando una mejora en los tiempos de respuesta para la clasificación. Sin embargo, debido a la velocidad de respuesta del clasificador K-nn la diferencia no es muy amplia.

Con el ajuste de la Wavelet madre se encontró que la DB8 era la mejor para la descomposición de las señales. No obstante, la diferencia con las otras familias no es muy amplia en cuanto a la clasificación se refiere. También se encontró que después de realizar la extracción de características y el análisis de relevancia, las

características de mayor importancia para la clasificación se hallaron en los niveles más altos de la descomposición (D5 y D6), demostrando así que las frecuencias bajas son la más importantes para la metodología propuesta y señalando una vez más la importancia de la descomposición Wavelet en cuanto a señales de EMG se refiere.

En la literatura no se encontró evidencia de estudios afines para el diagnóstico de lesiones plexo braquial. Aunque sí se encontraron metodologías similares para el diagnóstico de otro tipo de patologías (ver **Tabla 22**). Se puede comparar los resultados de precisión obtenidos mediante metodologías aplicadas al diagnóstico de otras lesiones, pero es de aclarar que, las bases de datos de las investigaciones referenciadas no se encontraron, y por esta razón, no se pudo comparar directamente la metodología propuesta en esta investigación con las otras, aunque si se puede evidenciar que en los estudios citados se obtuvieron buenos resultados con el clasificador K-nn.

**Tabla 22. Comparación de la metodología propuesta frente a otros estudios.**

ARTÍCULO Y AÑO	DISCRETIZACIÓN	CLASIFICACIÓN	MEJOR INDICE DE CLASIFICACIÓN	PATOLOGÍAS
Subasi (2013)	Wavelet, DB4 y 5 niveles.	K-nn, RBFN, SVM, PSO-SVM	95.17% para K-nn	Normal Neuropatía Miopatía
Subasi (2013)	Wavelet, DB4 y 5 niveles.	PSO-SVM.	97.60%	Normal Neuropatía Miopatía
Subasi (2012)	WPT, DB4, DB2 y 5 niveles.	Clasificadores ANN, DFNN, ANFIS	91.00%	Normal Neuropatía Miopatía
Metodología propuesta	Wavelet, DB8 y 6 niveles	K-nn	93.91%	Normal Esclerosis Lateral Amiotrófica Miopatía

La validación de los resultados obtenidos a partir de la aplicación de la metodología planteada presenta resultados de precisión comparable con los encontrados en la literatura y muestra que es eficaz para la clasificación de dos patologías en lesiones de plexo braquial. Además podría tener una repercusión positiva en la manera de diagnosticar este tipo de afecciones por los clínicos si se adoptara de manera generalizada. Por otra parte, al realizar un diagnóstico más rápido y reduciendo en gran medida la subjetividad de la prueba electromiográfica, el paciente podrá ser intervenido con mayor rapidez. Esto lograría aumentar la posibilidad de disminuir el compromiso de las capacidades motoras y garantizaría una recuperación más eficiente del mencionado.

En resumen, se presenta una metodología para la clasificación de señales EMG con Miopatía y Esclerosis Lateral Amiotrofia. Este método basado en la transformada Wavelet Discreta, y el análisis de relevancia, es simple y no demanda un alto coste computacional en comparación con otras metodologías propuestas en la literatura (ver **Tabla 22**). Los resultados obtenidos muestran que este método es una alternativa para la extracción de características y clasificación de las señales EMG. Del análisis de relevancia, se puede decir que no hay un método perfecto para la selección de características, y no tienen el 100% de concordancia, sin embargo, el análisis de relevancia permite una reducción de características (en este caso de un 79.59%) y una mejor Acc (%) en comparación con los resultados sin análisis de relevancia. Esto permite una clasificación adecuada con un pequeño número de características.

## CONCLUSIONES Y TRABAJO FUTURO

Respecto al primer objetivo específico “Caracterizar las señales de electromiografía mediante técnicas de descomposición tiempo-frecuencia orientado a comprender la dinámica de las señales de EMG”, se comprobó que la familia Daubechies 8 fue la más apropiada para seis niveles de descomposición utilizados en la caracterización de señales EMG. Si bien las diferencias estadísticas no fueron significativas entre las distintas familias probadas, las que obtuvieron la medida de clasificación más alta y la desviación estándar más pequeña fueron las familias Daubechies 8 y Biortogonal 6.8. Se debe tener en cuenta que la base de datos de las señales EMG se consiguieron pre-filtradas ya que no se encontró una base de datos sin pre-procesamiento. Para la caracterización se utilizaron particularidades estadísticas y de energía para cada nivel de descomposición encontrando una gran cantidad de información, esto hizo que fuera necesario realizar un análisis de relevancia para determinar las características que aportaban mayor información.

Respecto al segundo objetivo específico “Proponer un análisis de relevancia sobre el sistema de caracterización que permita reducir el espacio de alta dimensionalidad, y brinde información sobre las características más importantes para clasificación de señales de EMG”, es de anotar que el espacio de entrada estaba conformado por 49 características y por medio de un análisis de relevancia se logró reducir a 10 características con ED. Por otra parte, se encontró que entre los algoritmos de Entropía Difusa y Variabilidad Estocástica hubo concordancia en seis (6) características, tres en las medias aritméticas ( $\mu D1$ ,  $\mu D5$  y  $\mu D6$ ) y tres en la energía Hilbert-Shannon ( $EhD4$ ,  $EhD5$  y  $EhD6$ ). De manera que pudiera observarse la mayor información de la caracterización que se encuentra en los niveles más altos de la descomposición (D5 y D6), demostrando

con esto que las bandas altas son las más importantes y más discriminantes en la metodología propuesta.

En cuanto al tercer objetivo específico “Validar la metodología diseñada, en señales de EMG con lesiones del plexo braquial utilizando una estrategia de validación cruzada, con señales previamente anotadas por un experto”, se mostró que utilizando un algoritmo K-nn con tres vecinos se logró una clasificación con un desempeño del 93.91% y una  $\sigma = \pm 0.99\%$  para el diagnóstico de lesiones de plexo braquial. Con esta metodología se logró reconocer dos patologías, *Miopatía y Esclerosis Lateral Amiotrófica*, resultado que podría utilizar personal clínico para dar un diagnóstico de una lesión de plexo braquial en traumatismo cerrado con mayor asertividad. Es de aclarar que las señales se encuentran en una base de datos anotada anteriormente y que el sistema de clasificación no funciona en tiempo real debido a la gran cantidad de información que se genera a partir de las señales electromiográficas; por ésta razón, se hace necesario descomponer la señal y realizar un análisis de relevancia antes de efectuar la clasificación. Otras técnicas de clasificación como las SVM podrían aumentar el intervalo de confianza pero se vería comprometido el tiempo de respuesta del sistema en cuanto a clasificación se refiere. Por otra parte, se efectuó un ajuste del clasificador debido a que en la literatura encontrada la mayoría de autores utilizaban  $K=5$ . Dicho ajuste arrojó que el número adecuado de vecinos para proponer una metodología de clasificación de señales de electromiografía mediante el análisis tiempo-frecuencia, orientada al diagnóstico de lesiones de plexo braquial en traumatismo cerrado fue con  $K=3$ .

Como trabajo futuro, se propone realizar un análisis de atractores reconstruidos para este tipo de señales mediante técnicas de dinámica no lineal. Adicionalmente, se podrían construir espacios de representación dinámica con el fin de capturar patrones ocultos entre estados de funcionalidad a lo largo del eje del tiempo.

## Referencias

- Adeli, H., Zhou, Z., y Damehr, N. (2006). Analysis of EEG records in an epileptic patient using wavelet transform. *Journal of Neuroscience Methods*, 123(1), 168-187.
- Ahlstrom, C., Hult , P., Karlsson , E., Nylander, U., Dahlstrom , U., & Ask, P. (2006). Feature extraction systolic heart murmur classification. *Annals of Biomedical Engineering*, 34(11), 1666-1677.
- Alkan , A., & Günay, M. (2012). Identification of EMG signals using discriminant analysis and SVM classifier. *Expert Systems with Applications*, 39(1), 44-47.
- Amador., E. V. (2010). Reconstrucción de lesiones altas del plexo braquial en adultos. *Revista Colombiana de Ortopedia Y Traumatología*, 24.
- Arroyave, C. A. (29 de Octubre de 2014). ELA, una sentencia neurológica. *EL MUNDO*, págs. 10-12.
- Atlas, L., & Fang, J. (1992). Quadratic detectors for general nonlinear anylisis of speech. *International Conference on Acoustics, Speech and Signal Proceedings ICASSP*, 9-12.
- Belalcazár Sandoval, C. M., & Rengifo Varila, Z. V. (2007). CLASIFICACIÓN DE SEÑALES ELECTROMIOGRÁFICAS (EMG) PARA UNA PRÓTESIS DE MANO (pp. 24–26).

- Betancourt , G., Giraldo , E., & Franco , J. (2004). Reconocimiento de patrones de movimiento a partir de señales electromiográficas. *Scientia et Technica*, 3(26), 53-58.
- Bollini, C. (2004). Revisión anatómica del plexo braquial. *Revista Argentina de Anestesiología*, 62(6), 386-398.
- Carreño , I., & Vuskovic, M. (2007). wavelet-based feature extraction from prehensile emg signals. *Informatics in Control, Automation and Robotics II*, 235-242.
- Chen, Y., Akutagawa, M., Emoto, T., & Kinouchi, Y. . (2010). The removal of EMG in EEG by neural networks. *Physiological Measurement*, 31(2), 1567-1584.
- Christodoulou, C. I., Kaplanis, P. a., Murray, V., Pattichis, M. S., Pattichis, C. S., & Kyriakides, T. (2012). Multi-scale AM–FM analysis for the classification of surface electromyographic signals. *Biomedical Signal Processing and Control*, 7(3), 265–269. doi:10.1016/j.bspc.2012.01.001.
- Chuang, D. C.-C. (2008). Brachial plexus reconstruction based on the new definition of level of injury. *Injury*, 39 Suppl 3, S23–9. doi:10.1016/j.injury.2008.05.012.
- Crespo, J. P., Sánchez, R. H., Hurtado, P. E., & Baz, D. A. (2006). Análisis del EEG mediante la entropía wavelet para la ayuda en el diagnóstico de la enfermedad de Alzheimer, 531–534.
- Cui, J., & Wang , X. (2005). Annual International Conference of the IEEE Engineering in Medicine and Biology Society. The Application of Wavelet Transform and Neural Network to Surface Electromyographic Signals for Pattern Recognition (págs. 5009-5012). China: Engineering in Medicine and Biology Society.

- Daalen, V., Stassen, H., Thomeer, R., & Slooff, A. (1993). Computer assisted diagnosis and treatment planning of brachial plexus injuries. *Clinical Neurology and Neurosurgery*, 550-555.
- De Luca, A., & Termini, S. (1972). A definition of a nonprobabilistic entropy in the setting of fuzzy sets theory. *Information and Control*, 20(4), 301-312.
- Delgado, E.; Jaramillo, A.; Quiceno, F., & Manrique, G. (2007). 34th Annual Computers in Cardiology Conference . Parameter tuning associated with nonlinear dynamics techniques for the detection of cardiac murmurs by using genetic algorithms. North Carolina: Advancing Technology for Humanity.
- Dogliotti, A. (2011). Conceptos actuales en la parálisis braquial perinatal. Parte 1: etapa temprana. *Archivos Argentinos de Pediatría*, 109(4), 347–353. doi:10.5546/aap.2011.347.
- Doulah, A., Fattah, S., Zhu, W., & Ahmad, M. (2014). Wavelet domain feature extraction scheme based on dominant motor unit action potential of EMG signal for neuromuscular disease classification. *IEEE Trans Biomed Circuits Syst.*, 8(2), 155-164.
- Englehart , K., Hudgin, B., & Parker , P. (2001). A wavelet-based continuous classification scheme for multifunction myoelectric control. *Biomedical Engineering, IEEE .*, 48(3), 302-311.
- Figliola, A., & Serrano, E. (1997). Analysis of physiological time series using wavelet transforms. *Engineering in Medicine and Biology Magazine*, 16(3), 74-79.

- Fodor, I. K. (2002). A survey of dimension reduction techniques. Center for Applied Scientific Computing, Lawrence Livermore National Laboratory, (1), 1-18.
- Forero, L., & Valvuenza, C. (2009). Muertes y lesiones por accidentes de tránsito Colombia. *Forensis*, 237-275.
- Friedman, J. (1997). On Bias, Variance, 0/1—Loss, and the Curse-of-Dimensionality. *Data Mining and Knowledge Discovery*, 55-77.
- Gallego Y., G. H. (2009). Caracterización de personas lesionadas en accidentes de tránsito ocurridos en Medellín y atendidas en un hospital de tercer nivel 1999-2008. *Facultad Nacional de Salud Pública*, 105-116.
- García, A., & López, L. (2003). Cronología en la cirugía de las lesiones del plexo braquial. *Revista Española de Cirugía Ortopédica y Traumatología*, 47(1), 73-82.
- Ghaderyana, P., Abbasia, A., & Hossein, M. (2014). An efficient seizure prediction method using KNN-based undersampling and linear frequency measures. *Journal of Neuroscience Methods*, 232, 134-142.
- Gila, L., Malanda, A., Rodríguez, I., Rodríguez, J., & Navallas, J. (2009). Métodos de procesamiento y análisis de señales electromiográficas. *Anales del Sistema Sanitario de Navarra*, 27-43.
- Graupe, D., Salahi, J., & Kohn, K. (1982). Multifunctional prosthesis and orthosis control via microcomputer identification of temporal pattern differences in single-site myoelectric signals. *Journal of Biomedical Engineering*, 4(1), 17-22.

- Hargrove, L., Englehart, K., & Hudgins, B. (2007). A Comparison of Surface and Intramuscular Myoelectric Signal Classification. *Biomedical Engineering, IEEE*, 54(5), 847-853.
- Hu, J., Wang, C., Wu, M., Du, Y., He, Y., & She, J. (2015). Removal of EOG and EMG artifacts from EEG using combination of functional link neural network and adaptive neural fuzzy inference system. *Neurocomputing*, 151, 278-287.
- Hudgins, B., Parker, P., & Robert, N. (1993). New Strategy for Multifunction Myoelectric Control. *Biomedical Engineering*, 40(1), 82-94.
- Jaimes, A., Durán, C., & Mendoza, L. (2010). Diseño de un registrado electromiográfico de superficie para cuantificar unidades motoras en la enfermedad del pie caído. *Revista Colombiana de Tecnologías de Avanzada*, 2(16), 57-62.
- Kaiser, J. (1990). On a simple algorithm to calculate the energy of a signal. *International Conference on Acoustics, Speech, and Signal Processing ICASSP 90*, 381-384.
- Kaufmann, P., Englehart, K., & Platzner, M. (2010). Fluctuating emg signals: Investigating long-term effects of pattern matching algorithms. *Engineering in Medicine and Biology Society*, 6357-6360.
- Kaur, G., Shatru, A., & Kumar, V. (2010). EMG Diagnosis via AR Modeling and Binary Support Vector Machine Classification. *International Journal of Engineering Science and Technology*, 2(6), 1767-1772.
- Lee, H.-M., Chen, C.-M., Chen, J.-M. , & Jou, Y.-L. (2001). An efficient fuzzy classifier with feature selection based on fuzzy entropy. *IEEE Systems, Man, and Cybernetics Society*, 31(3), 426-432.

- Liang, H., Lukkarinen, S., & Hartimo, I. (1998). A boundary modification method for heart sound segmentation algorithm. *Computers in Cardiology*, 593-595.
- Limthongthang, R., Bachoura, A., Songcharoen, P., & Osterman, a L. (2013). Adult brachial plexus injury: evaluation and management. *The Orthopedic Clinics of North America*, 44(4), 591–603. doi:10.1016/j.ocl.2013.06.011.
- Liu, H., Chen, X., & Chen, Y. (2005). Wavelet transform and real-time learning method for myoelectric signal in motion discrimination. *Journal of Physics: Conference Series* Email alert RSS feed, 36, 250-253.
- Liu, J. (2014). Feature dimensionality reduction for myoelectric pattern recognition: A comparison study of feature selection and feature projection methods. *ELSEVIER*, 36, 1716–1720.
- Mannan, K., & Carlstedt, T. (2006). Injuries to the brachial plexus. *Surgery (Oxford)*, 24(12), 409–414. doi:10.1053/j.mpsur.2006.10.004.
- Martínez, J., & Ruiz, R. (2004). Congreso Anual de la Sociedad Española de Ingeniería Biomédica. Compresión de fonocardiogramas mediante las transformadas wavelet y wavelet packet (págs. 181-184). España: Sociedad Española de Ingeniería Biomédica.
- Medina, B. (2013). Diseño de una metodología para la extracción de características de electroencefalografía en sistemas con interfaz cerebro computador. Medellín: Instituto Tecnológico Metropolitano, Trabajo de grado para optar al título de Magíster en Automatización y Control.

- Michael, E., & Christopher M. (1999). Probabilistic Principal Component Analysis. *Journal of the Royal Statistical Society. Series B (Statistical Methodology)*, 61, 611–622.
- Mills, K. (2005). The basics of electromyography. *J Neurol Neurosurg Psychiatry*, 76(2), ii32-ii35.
- Nakariyakul, S., & Casasent, D. P. (2009). An improvement on floating search algorithms for feature subset selection. *Pattern Recognition*, 42(9), 1932–1940. doi:10.1016/j.patcog.2008.11.018.
- Nikolic, M. (2001). Detailed Analysis of Clinical Electromyography Signals EMG Decomposition, Findings and Firing Pattern Analysis in Controls and Patients with Myopathy and Amyotrophic Lateral Sclerosis. Recuperado el 2 de Junio de 2014, de University of Copenhagen: <http://www.emglab.net>
- Oberlin, C., Chino, J., & Belkheyar, Z. (2013). Surgical treatment of brachial plexus posterior cord lesion: a combination of nerve and tendon transfers, about nine patients. *Chirurgie de La Main*, 32(3), 141–6. doi:10.1016/j.main.2013.04.002.
- OMS. (2004). Informe mundial sobre prevención de los traumatismos causados por el tránsito. Ginebra: Organización Mundial de la Salud.
- Oskoei, M., & Hu, H. (2008). Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb. *Biomedical Engineering, IEEE*, 55(8), 1956-1965.
- Parkash, O., Sharma, P., & Manahan, R. (2008). New measures of weighted fuzzy entropy and their applications for the study of maximum weighted fuzzy entropy principle. *Information Sciences*, 178(11), 2389-2395.

- Peña, D. (2002). Análisis de datos multivariante. (S. A. M.-H. / I. DE ESPAÑA, Ed.) Análisis de datos multivariantes. Mc Graw Hill, 2002. (p. 529).
- Phinyomark, A., Phukpattaranont, P., & Limsakul, C. (2012). Feature reduction and selection for EMG signal classification. *Expert Systems with Applications*, 39(8), 7420–7431. doi:10.1016/j.eswa.2012.01.102.
- Pino L., S. D. (2010). Probabilistic muscle characterization using QEMG: application to neuropathic muscle. *Muscle Nerve*, 41(1), 18-31.
- Pino, L., Stashuk, D., Boe, S., & Doherty, T. (2009). Decision support for QEMG. En *S. t. Neurophysiology, Motor Unit Number Estimation (MUNE) and Quantitative EMG* (págs. 247-260). Canadá: M.B. Bromberg.
- Pino, L., Stashuk, D., Boe, T., & Doherty, S. (2008). Motor unit potential characterization using “pattern discovery”. *Medical Engineering & Physics*, 30(5), 563-573.
- Poza, J., Abásolo, D., Gómez, C., Sánchez, C., & López, M. (2004). 11th International Workshop of Systems, Signals and Image Processing (IWSSIP'2004). "Use of Wavelets Packets to Compare Electroencephalogram Signals (EEG) in Patients with Alzheimer's Disease and Control Subjects" (págs. 35-38). Polonia: 11th International Workshop of Systems, Signals and Image Processing (IWSSIP'2004).
- Poza, J., Hornero, R., Espino, P., & Abásolo, D. (2006). Análisis del EEG mediante la entropía wavelet para la ayuda en el diagnóstico de la enfermedad de Alzheimer. XXIV Congreso Anual de la Sociedad Española de Ingeniería Biomédica (págs. 6-8). Pamplona: Sociedad Española de Ingeniería Biomédica.

- Quiceno, A. (2009). Análisis tiempo-frecuencia por métodos no paramétricos orientado a la detección de patologías en bioseñales. Bogotá DC: Universidad Nacional de Colombia.
- Quiceno, A., Hernández, A., & Travieso, G. (2009). Detección de perturbaciones en la variabilidad del ritmo cardiaco a través de análisis tiempo frecuencia aplicado sobre la serie RR extraída a partir de la señal electrocardiográfica para detección de apnea obstructiva del sueño. Pereira: XIV Simposio de Tratamiento de Señales, Imágenes y Visión Artificial.
- Raez, M., Hussain, F., & Yasin, M. (2006). Techniques of EMG signal analysis: detection, processing, classification and applications. *Biological Procedures Online*, 8(1), 11-35.
- Rafiee, J., Rafiee, M., Prause, N., & Schoen, M. (2011). Wavelet basis functions in biomedical signal processing. *Expert Systems with Applications*, 38, 6190-6201.
- Ravits, J. (2014). Focality, stochasticity and neuroanatomic propagation in ALS pathogenesis. *Experimental Neurology*, 262, 121–126. doi:10.1016/j.expneurol.2014.07.021
- Rencher, A. C. (2005). A Review Of “Methods of Multivariate Analysis, Second Edition.” *IIE Transactions* (Vol. 37, pp. 1083–1085). doi:10.1080/07408170500232784.
- Roa, S., & Loaiza, H. (2011). Evaluación de técnicas para el análisis de relevancia basadas en filtros sobre imágenes radiológicas. *Revista de Ingeniería Biomédica*, 5(9), 26-34.
- Romo, H. A., Realpe, J. C., Jojoa, P. E., & Cauca, U. (2007). Análisis de Señales EMG Superficiales y su Aplicación en Control de Prótesis de Mano Surface

- EMG Signals Analysis and Its Applications in Hand Prosthesis Control, 4(1).
- Ruiz, R., Riquelme, J. C., & Ruiz, S. A. (2005). Búsqueda secuencial de subconjuntos de atributos sobre un ranking, 251–260.
- Saini, I., Singh, D., & Khosla, A. (2013). QRS detection using K-Nearest Neighbor algorithm (KNN) and evaluation on standard ECG databases. *Journal of Advanced Research*, 4, 331-344.
- Sepúlveda, L. (2013). *Dynamic Relevance Analysis in Biosignals Thesis for the degree of Dr. Eng. — Automatics*. Manizales: Universidad Nacional de Colombia.
- Sijiang, D. (2003). *Feature Extraction for Classification of Prehensile Electromyography Patterns*. San Diego: San Diego State University.
- Subasi, A. (2012). Classification of EMG signals using combined features and soft computing. *Applied Soft Computing*, 12, 2188-2198.
- Subasi, A. (2013). Classification of EMG signals using PSO optimized SVM for diagnosis. *Computers in Biology and Medicine*, 43, 576-586.
- Subasi, A., & Kiyimik, K. (2010). Muscle Fatigue Detection in EMG Using Time–Frequency Methods, ICA and Neural Networks. *Journal of Medical Systems*, 34(4), 777-785.
- Swiontkowski, M. (2005). *Manual de Ortopedia y Traumatología*. Barcelona: MASSON S.A.
- Tipping, M. E., & Bishop, C. M. (2006). *Mixtures of Probabilistic Principal Component Analysers*.

- Trujillo Pulgarin, C. A. (2012). Clasificación basada en la estimación de Parzen en espacios generalizados de disimilitudes. (Universidad Nacional de Colombia, Ed.) (pp. 12–18).
- Van Alfen, N., & Martijn, M. (2013). Diagnosis of brachial and lumbosacral plexus lesions Handbook of Clinical Neurology. En N. Van Alfen, & M. Martijn, Handbook of Clinical Neurology (págs. 293-310). Gérard Said and Christian Krarup.
- Vergara, E. (2010). Reconstrucción de lesiones altas de plexo braquial en adultos. *Revista Colombiana de Ortopedia y Traumatología*, 24(1), 19-25.
- Wang, X., Liu, X., Pedrycz, W., & Zhang, L. (2015). Fuzzy rule based decision trees. *Pattern Recognition*, 48(1), 50–59. doi:10.1016/j.patcog.2014.08.001.
- Xiao, Z., Yu, Y., Xiao, X., Hu, T., Zhong, G., Jian, Z., y otros. (2005). Clinical detection and movement recognition of neuro signals. *Journal of Zhejiang University Science B*, 272-279.
- Zecca, M., Micera, S., Carroza, M., & Dario, P. (2002). Control of Multifunctional Prosthetic Hands by Processing the Electromyographic Signal. *Critical Reviews in Biomedical Engineering*, 30(4), 459-485.
- Zhang, X., Yang, Y., Xu, X., & Zhang, M. (2002). Communications, Circuits and Systems and West Sino Expositions, IEEE 2002 International Conference on Communications. Wavelet based neuro-fuzzy classification for EMG control (págs. 1087-1089). China: IEEE 2002 International Conference on Communications.