



**UNIVERSIDAD AUTÓNOMA DE QUERÉTARO**  
**FACULTAD DE INGENIERÍA**  
**CAMPUS AEROPUERTO**



**Metodología para la identificación de movimientos de la  
mano en personas mediante análisis tiempo-frecuencia  
en señales emg.**

**TESIS**

Como parte de los requisitos para obtener el título de

**INGENIERO BIOMÉDICO**

Línea Terminal

**BIOSEÑALES Y BIOINSTRUMENTACIÓN**

Presenta

**Moises Martin Contreras Morales**

Directores

**Dr. Carlos Andrés Pérez Ramírez**

Santiago de Querétaro, Querétaro, Febrero de 2023.



Dirección General de Bibliotecas y Servicios Digitales de  
Información



Metodol

**por**

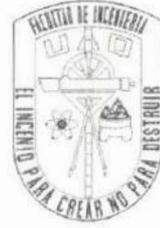
Moises Martin Contreras Morales

se distribuye bajo una [Licencia Creative Commons  
Atribución-NoComercial-SinDerivadas 4.0 Internacional](#).

**Clave RI:** IGLIN-262945-0223-423



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO  
FACULTAD DE INGENIERÍA  
CAMPUS AEROPUERTO



**Metodología para la identificación de movimientos de la mano en personas mediante análisis tiempo-frecuencia en señales EMG.**

Tesis

Que como parte de los requisitos para obtener el título de Ingeniero Biomédico.

Presenta:

Moises Martín Contreras Morales

Dirigido por:

Dr. Carlos Andrés Pérez Ramírez

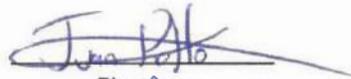
Dr. Carlos Andrés Pérez Ramírez  
Presidente



---

Firma

Dr. Juan Pablo Amézquita Sánchez  
Secretario



---

Firma

Dr. Jesús Alberto Basurto Hurtado  
Vocal



---

Firma

LDI. Alejandro Antonio Salinas Aguilar  
Suplente



---

Firma

Centro Universitario  
Querétaro, Qro.  
Febrero 2023

## Resumen

La medición así como el análisis a través de distintas muestras de las señales EMG se utilizan en el diagnóstico clínico de trastornos neuromusculares. Una de las aplicaciones comúnmente utilizadas en distintos trabajos de investigación donde se detallan metodologías para la adquisición de señales, mencionan que el procesamiento se hace solo mediante una descomposición de tiempo-frecuencia como la transformada Wavelet, la cual es una herramienta matemática eficiente para el análisis local de señales que son transitorias, rápidas y no estacionarias. Sin embargo, esta herramienta por sí sola no ofrece una diferenciación para aquellas señales en un intervalo de tiempo no discreto o en tiempo real. A través de herramientas de descomposición de señales tiempo-frecuencia, dimensiones fractales, un algoritmo de descomposición y un clasificador basado en el aprendizaje máquina, se desarrolló una metodología que permita identificar tres distintos movimientos de la mano con señales de 2 canales. Como primer paso, se llevará a cabo el procesamiento digital de las señales EMG, tras su lectura y entendimiento, se emplearon algoritmos tiempo-frecuencia avanzados que permitan descomponer las señales EMG ya sea en sus componentes fundamentales o en las bandas de frecuencia determinadas por las características de la señal. Esto se realizó empleando métodos estadísticos que midan el grado de independencia entre ellas. Los resultados obtenidos previamente utilizando el método propuesto representan una precisión del 71.4% para distinguir los movimientos Índice (I), Medio (M) y Meñique (L). Esto se logra utilizando técnicas de baja carga computacional como WPT, parámetros de Hjorth y técnicas de FD. Entre las principales perspectivas están: Una etapa intermedia más extensa para la selección de algoritmos para el procesamiento de la señal, crear un sistema de adquisición de señales de EMG para comprobar el desempeño de la metodología con datos propios adquiridos y en tiempo real además de incluir de todos los movimientos individuales y las combinaciones de las flexiones de los dedos de la mano.

**Palabras Clave:** Señales EMG, Dimensión fractal, ANOVA, Metodología, Perceptrón multicapa

## **Dedicatoria**

Dedico esta tesis con toda mi estima y agradecimiento

A mis padres que fueron parte fundamental para lograr este objetivo

A mis amigos Gustavo García, Elizabeth Cadenas, Lizzette Mendoza, Marzela Osti, Gabriela Pacheco, Chabelly Ramírez, Karla Arriaga, Fatima Xocoyotl, y Brandon Vidal quienes fueron un gran apoyo emocional durante el tiempo en que escribía esta tesis.

A todos mis maestros, mentores y sinodales que han puesto su confianza en mi para lograr todas las metas que me propuse y que ellos mismos propusieron.

Y a todas la personas que han creído a mí y me han ayudado a comprender que tan lejos puedo llegar en mi vida.

## Agradecimientos

En primer lugar, deseo expresar mi agradecimiento al Director de esta tesis de licenciatura, Dr. Carlos Andres Perez Ramírez, por la dedicación, por el apoyo que ha brindado a este trabajo, por su respeto a mis sugerencias e ideas, y por la dirección y disciplina que les ha dado. Gracias por la confianza que me han brindado desde que llegué a esta facultad.

Asimismo, agradezco a mis compañeros de la carrera de Ingeniería Biomédica por su apoyo personal y humano, especialmente a la Lic. Rosalía Manchuca y a la Lic. Mariana Barcenás, con quien he trabajado mi autoestima, mi salud mental y mi resiliencia.

Un trabajo de investigación es siempre fruto de ideas, proyectos y esfuerzos previos que corresponden a otras personas. En este caso mi más sincero agradecimiento al Dr. Juan Pablo Amezcuita, del campus San Juan del Río, que cuyo conocimiento ha sido fundamental para el desarrollo de esta tesis. Gracias por su tiempo y paciencia para explicar su proyecto como parte de la materia de Procesamiento de bioseñales.

Sin embargo, el trabajo de investigación es también fruto del reconocimiento y apoyo imprescindible de personas que nos valoran, sin las cuales no tendríamos la voluntad y la energía para seguir creciendo como personas y como profesionales.

Gracias a mi familia, a mis padres y a mi hermana, porque con ellos han compartido y han visto mi esfuerzo para llegar hasta donde estoy.

Gracias a mis amigos, que siempre me han brindado un enorme apoyo moral y humano, que ha sido crucial en este momento tan difícil para este trabajo y esta profesión.

A todos, muchas gracias.

# 1 Contenido

<b>CAPÍTULO 1 INTRODUCCIÓN</b> .....	<b>6</b>
<b>1.1. Introducción</b> .....	<b>6</b>
<b>1.2. Antecedentes</b> .....	<b>7</b>
<b>1.3. Justificación</b> .....	<b>9</b>
<b>1.4. Descripción del problema</b> .....	<b>10</b>
<b>1.5. Hipótesis y objetivos</b> .....	<b>11</b>
1.5.1. Hipotesis.....	11
1.5.2. Objetivo General .....	11
1.5.3. Objetivos particulares.....	12
<b>1.6. Planteamiento general del problema</b> .....	<b>12</b>
<b>CAPÍTULO 2 FUNDAMENTACIÓN TEÓRICA</b> .....	<b>13</b>
<b>2.1. Señales EMG</b> .....	<b>13</b>
2.1.1. Adquisición de señales EMG .....	13
2.1.2. Placa Motora .....	14
2.1.3. Sensores.....	16
<b>2.2. Herramientas de descomposición de señales tiempo-frecuencia</b> .....	<b>18</b>
2.2.1. Transformada Wavelet .....	19
2.2.2. Tranformada Wavelet por paquetes .....	20
<b>2.3. Características no lineales</b> .....	<b>22</b>
2.3.1. Fractales .....	22
2.3.2. Box Fractal Dimension.....	23
2.3.3. Katz .....	23
2.3.4. Higuchi .....	24
2.3.5. Sevcik.....	24

2.3.6.	Medias de Textura.....	25
2.3.7.	Parámetros de Hjorth.....	26
2.3.8.	ANOVA.....	27
2.3.9.	ANOVA no Paramétrico.....	28
2.3.10.	Valor-P.....	28
<b>2.4.</b>	<b>Redes Neuronales.....</b>	<b>28</b>
2.4.1.	Arquitectura y topología .....	29
2.4.2.	Aprendizaje supervisado .....	31
2.4.2.1.	Algoritmo de entrenamiento .....	31
<b>CAPÍTULO 3 METODOLOGÍA .....</b>		<b>33</b>
<b>3.1.</b>	<b>Metodología Propuesta .....</b>	<b>33</b>
<b>3.2.</b>	<b>Descripción de la base de datos empleada.....</b>	<b>35</b>
3.2.1.	Participantes y procedimientos.....	35
3.2.2.	Adquisición de los datos .....	35
<b>CAPÍTULO 4 EXPERIMENTACIÓN Y RESULTADOS .....</b>		<b>37</b>
<b>4.1.</b>	<b>Resultados obtenidos .....</b>	<b>37</b>
<b>4.2.</b>	<b>Discusión de resultados .....</b>	<b>51</b>
<b>CAPÍTULO 5 CONCLUSIÓN Y PROSPECTIVAS.....</b>		<b>54</b>
<b>5.1.</b>	<b>Conclusiones.....</b>	<b>54</b>
<b>5.2.</b>	<b>Prospectivas.....</b>	<b>55</b>
<b>REFERENCIAS BIBLIOGRÁFICAS .....</b>		<b>56</b>

# CAPÍTULO 1

## INTRODUCCIÓN

### 1.1. Introducción

Recientemente, se han realizado muchas investigaciones sobre dispositivos conectados al cuerpo humano para mejorar la capacidad de movimiento así como el desarrollo de nuevas invenciones en la rehabilitación. La electromiografía de superficie (sEMG) se usa comúnmente para una evaluación no invasiva de una señal mioeléctrica. En la mayoría de los casos, se selecciona este tipo, ya que es indoloro y fácil de adquirir. La medición así como el análisis a través de distintas muestras de las señales sEMG se utilizan en el diagnóstico clínico de trastornos neuromusculares, el estudio de fatiga y el control de prótesis. Hoy en día la utilización de este tipo de señales se ha señalado como fuente primaria de control de extremidades protésicas debido a su fácil manejo (Day, 2002).

Existen varios métodos para controlar las prótesis, por ejemplo puede utilizar una variedad de señales fisiológicas humanas. Entre ellas, la señal EMG tiene las características de adquisición simple de correlación directa con la contracción y relajación de las fibras musculares, por lo que es ampliamente utilizada. Utilizado en medicina clínica, medicina de rehabilitación, inteligencia artificial y otros aspectos se pueden crear dispositivos que simulen de manera eficaz el movimiento de una extremidad.

En este sentido, es evidente que para desarrollar las aplicaciones necesarias para interpretar las señales adquiridas, ya que de esta manera será posible determinar la acción que se desea efectuar. Existen diversas estrategias de procesamiento de señales que pueden usarse para identificar las diferentes características que puedan detectar los diferentes estados que la mano puede tener usando un clasificador; sin embargo, la mayoría de ellos requiere de un tiempo de procesamiento considerable. Por tal motivo, esta tesis se enfoca en realizar una búsqueda exhaustiva de los diversas herramientas existentes para que en conjunto con un clasificador apropiado, desarrollar una metodología que permita detectar los diferentes movimientos que la mano puede tener usando algoritmos de baja carga computacional; de

esta manera, se podría implementar la metodología desarrollada en una prótesis de mano logrando su control en tiempo real.

## 1.2. Antecedentes

En años recientes, varios investigadores de distintas partes del mundo han propuesto metodologías para detectar los movimientos de la mano a través de la obtención de señales de EMG. Edgar Douglas Adrian premio Nobel de Medicina en 1932 por sus descubrimientos relacionados con el funcionamiento de las neuronas, colaboró con el fisiólogo estadounidense Detlef Bronk en un experimento para cuantificar la acción generada por una sola fibra nerviosa. Utilizaron un electrodo de aguja y un altavoz para registrar la actividad eléctrica de las fibras musculares que se generan a través de una sola fibra nerviosa, que más tarde se llamaría "Unidad de Potencial Motor". (Adrian y Bronk, 1929).

Diferentes avances en estos ámbitos han ayudado al desarrollo de extremidades protésicas superiores. Una de las aplicaciones más comúnmente utilizadas en distintos trabajos de investigación donde se detallan metodologías para la adquisición de señales, mencionan que el procesamiento se hacía solo mediante una descomposición de tiempo- frecuencia como la WT (*Wavelet Transform*, en inglés) la cual es una herramienta matemática eficiente para el análisis local de señales que son transitorias, rápidas y no estacionarias.

Una de las principales propiedades de WT es que se puede implementar mediante un banco de filtros de tiempo discreto. Sin embargo, esta herramienta por sí sola no ofrece una diferenciación para aquellas señales en un intervalo de tiempo no discreto o en tiempo real. Una muestra de esto es el trabajo de (Harada, et al., 2008) propusieron un nuevo método para la estimación del valor RMS (Root-Mean-Square, en inglés) del electromiograma mediante el uso del análisis wavelet shrinkage y la transformada M. Esta transformación se basa en la propiedad pseudo-ortogonal de una secuencia M-pseudoaleatoria. Al igual que en el caso de la transformada de Fourier, donde cualquier señal de tiempo puede expresarse como una suma de señales sinusoidales, “cualquier función de tiempo periódica puede considerarse una suma ponderada de M-secuencias” (Hiroshi, et al., 2008). A partir de los resultados del experimento, el método propuesto es muy eficaz para eliminar el ruido impulsivo incluido en la señal RMS.

Estas variantes ofrecen una forma de disipar el ruido de la señal en su adquisición, aun así para los estándares actuales solo supone una pequeña parte de análisis necesario para la diferenciación de señales en electromiografías. Una técnica relacionada es el análisis A-ARMA (Adaptive Auto Regressive-Moving Average, en inglés) de las señales EMG registradas en la región del nervio cubital de la mano derecha en posición de reposo empleada por (Barişçi, 2008). El método A-ARMA, especialmente en el cálculo de los espectros de señales estacionarias, se utiliza para el análisis de frecuencia de señales, que dan una respuesta de frecuencia como picos así como valles agudos. En este estudio, como resultado del análisis del método A-ARMA de las señales EMG en el dominio de frecuencia-tiempo junto con un filtro para eliminar las señales ruidosas que se originan en la línea eléctrica y del sistema de adquisición de la señal, se obtuvieron curvas de espectro de frecuencia (histograma). Los métodos paramétricos se basan en modelar la secuencia de datos como la salida de un sistema lineal caracterizado por una función de sistema racional con la cual se hizo un clasificador para detectar entre tres grupos de individuos según los grados de degeneración de los nervios motores, 22 personas tenían miopatía, 43 tenían neuropatía y 28 eran personas sin ninguna patología, obteniendo una efectividad de entre 64 al 74%.

Con la llegada de software adaptado a las nuevas tecnologías de adquisición de datos, surgieron mejores metodologías para comparar diferentes movimientos de la mano y el antebrazo, en 2018 el equipo de Pacholi y Joshi han propuesto un sistema de adquisición de señales EMG multicanal eficaz para la aplicación de prótesis de miembros superiores. Se han realizado varios ejercicios de brazos para obtener señales EMG de cinco músculos diferentes del brazo para la validación del hardware desarrollado. La posición del músculo se seleccionó mediante el método de palpación. Además, los algoritmos de clasificación se han examinaron siete actividades diferentes. Se eligieron un total de 29 sujetos (25 intactos y cuatro amputados) para adquirir los datos EMG mediante estas actividades. Para clasificar el conjunto de datos EMG registrados, se han extraído nueve características del dominio del tiempo y siete del dominio de la frecuencia. Se presenta un análisis comparativo de diferentes clasificadores como k-NN (k-nearest neighbors), LDA (linear discriminant analysis), QDA (quadratic discriminant analysis), SVM (Support Vector Machine), RT (Random Tree) y Random Forest (RF). Los algoritmos de procesamiento y

clasificación de señales se procesaron en MATLAB 2016<sup>a</sup> dependiendo del clasificador así como el canal medido se obtuvieron diferentes resultados los cuales muestran el máximo rendimiento en el caso de un clasificador de RF de 92,07% y 91,56% respectivamente. Sin embargo, para el clasificador LDA se tiene un mínimo de 57,68%.

En la nueva década se han ido actualizando estas herramientas para el desarrollo de nuevas tecnologías ya que también se requiere la mejora continua del nivel de vida de las personas con discapacidad, por lo cual un trabajo actualizado desarrollado en (Chen & Liu, 2020). proponen un método de control de brazo robótico basado en la señal de electromiografía de superficie (sEMG) del antebrazo. En primer lugar, los datos de EMG de 16 canales del antebrazo se obtienen a través del instrumento de adquisición de EMG multicanal, se extraen las características, luego los gestos se clasifican e identifican mediante la máquina de vectores de soporte (SVM) algoritmo, y las señales se transmiten finalmente al brazo robótico, para que las personas puedan operar el brazo robótico a distancia a través de señales sEMG en tiempo real, su propósito esencial era el disminuir el número de canales para reducir el costo y, al mismo tiempo, garantizar una tasa de reconocimiento alta y utilizable. Los experimentos se realizaron recolectando señales EMG de la superficie del antebrazo de ocho voluntarios sanos. Los resultados experimentales muestran que la tasa de precisión del reconocimiento de gestos general del sistema puede alcanzar hasta el 90%, y el sistema responde rápidamente, sentando una buena base para manipular miembros artificiales en el futuro.

### **1.3. Justificación**

Actualmente, el sistema de salud mexicano atiende a menos del 5% de las personas con discapacidad por amputación o de falta del miembro superior. Las instituciones públicas encargadas de prestar servicio no tienen los recursos necesarios para solventar la demanda del país. Los reportes indican (Vázquez, 2015, p.2-3) que el DIF nacional solo cuenta con 11 unidades en todo el país donde se fabrican 400 prótesis al año debido a sus escasos recursos, el Instituto Nacional de Rehabilitación (INR) aporta 120 prótesis por año mientras que el Hospital Militar también tiene un programa de rehabilitación y prototización, pero no reporta el dato preciso.

En nuestra entidad, el CRIMAL IAP Querétaro como institución privada produce prótesis para 130 pacientes al año. Los CRIT también utilizan el sector privado para la realización de sus prótesis, proporcionando así a 775 pacientes al año.

Aunque con algunas excepciones, en el sector privado con la popularización de la manufactura de bajo costo y la reducción del tiempo de fabricación de prótesis han surgido como iniciativa ante esta problemática, esta tecnología se encuentra muy lejos de ser una solución fiable en este punto. En este sentido, varias metodologías se han desarrollado para la implementación de nuevas prótesis.

Aunque muchas de las herramientas de software de alto nivel para señales de EMG están disponibles en el mercado siguen teniendo un precio elevado, es por esto que en la rama de las ciencias biomédicas se han incluido bibliotecas y bases de datos de diferentes estudios para la creación de nuevas opciones de investigación en este tema. Las señales de sEMG como se ha referido no conllevan ningún riesgo y son muy fáciles de adquirir, con las ventajas que esto conlleva se puede contemplar una metodología más eficaz para la diferenciación de características en la señales de EMG.

En el presente trabajo, con los puntos ya mencionados este trabajo pretende utilizar la descomposición EMD (Empirical Mode Decomposition) para extraer la información necesaria de cada uno de los movimientos de la mano contenidos en la base de datos citada en segmentos denominados IMF (Intrinsic Mode Functions). Para caracterizarlos a través de métodos estadísticos en distintas bandas de frecuencia de la señal de EMG y finalmente emplear un clasificador basado en inteligencia artificial. Esto proporcionaría información necesaria para extraer características que puedan diferenciar movimientos de la mano para la construcción de una prótesis con las cualidades necesarias para realizar un movimiento controlado.

#### **1.4. Descripción del problema**

En México el INEGI reporta que el número de amputados es de cerca de 780 000 en el 2015 de los cuales el 82% de los casos es debido a enfermedades vasculares derivadas de la Diabetes Mellitus Tipo 2(DT2), el 16% representa el número de personas amputadas por un

proceso traumático y el 2% restante corresponden a amputaciones por tumores malignos o enfermedades congénitas (Vázquez, 2015). Esto es relevante en el sentido de que actualmente en México se necesita el desarrollo de tecnología para personas que pierden alguna de las extremidades. Esta información también podría revelar que los individuos en esta situación pierden de un ingreso económico al no cumplir con las demandas de distintos ambientes laborales.

El tener una discapacidad de miembro superior en nuestro país en la actualidad representa una disminución considerable en la calidad de vida en consecuencia a los pocos servicios existentes en la República, por lo que es necesario crear alternativas de bajo costo para distintos sectores de la población. Los procesos utilizados en la fabricación de prótesis son lentos, tediosos y demandan habilidades artesanales por parte de los protesistas mismos que, según la Sociedad Mexicana de Ortesistas y Protesistas (2015), solo 20% tiene alguna certificación o estudio. El desarrollo de nuevas metodologías para crear dispositivos con los estándares necesarios, podrían cubrir la demanda de prótesis para personas con amputaciones

## **1.5. Hipótesis y objetivos**

### **1.5.1. Hipotesis**

A través de herramientas de descomposición de señales tiempo-frecuencia, dimensiones fractales, un algoritmo de descomposición y un clasificador basado en el aprendizaje máquina, se identificarán distintos movimientos de la mano con señales de 2 canales permitirá desarrollar una metodología que permita identificar 3 distintos movimientos de la mano asociados a la pronación y sujeción de objetos.

### **1.5.2. Objetivo General**

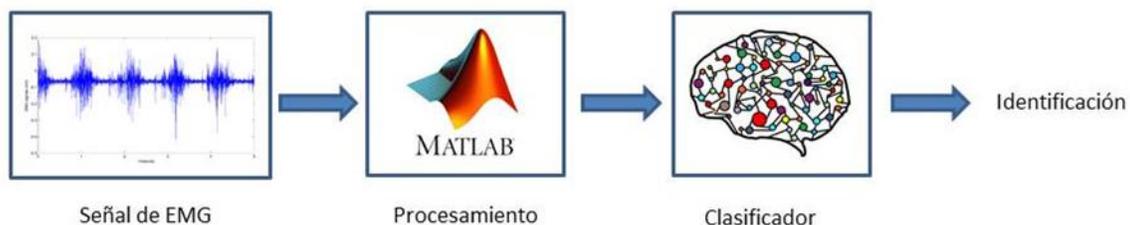
Desarrollar una metodología para la detección de distintos movimientos de la mano empleando herramientas de descomposición de señales tiempo-frecuencia, dimensiones fractales, un algoritmo de descomposición y un clasificador basado en inteligencia artificial.

### 1.5.3. Objetivos particulares

1. Realizar la descomposición de las señales de EMG empleando EMD a fin de encontrar alguna IMF que tenga información relevante para poder ser usada para diferenciar entre los distintos movimientos de la mano.
2. Programar los algoritmos de estimación de la FD, para poder cuantificar los cambios que se tienen en cada una de las bandas de frecuencia de las señales de EMG.
3. Realizar un análisis exhaustivo, empleando métodos estadísticos como: la entropía y medidas de textura de las características encontradas, a fin de determinar la banda de frecuencia que contiene los mayores cambios.
4. Programar un clasificador basado en inteligencia artificial que genere un sistema que determine a qué clase de movimiento pertenece cada muestra.
5. Evaluar la eficacia de cada uno de los clasificadores desarrollados, empleando una matriz de confusión como métrica de rendimiento, para determinar el más eficiente.

### 1.6. Planteamiento general del problema

A continuación, se presenta un planteamiento general de cómo se llevará a cabo la tesis (figura 1), la cual en general comprenderá cuatro etapas distintas:



*Figura 1.1 Planteamiento General.*

Como primer paso, se llevará a cabo el procesamiento digital de las señales EMG, tras su lectura y entendimiento. El objeto de esta etapa es encontrar características propias de cada movimiento que nos permitan diferenciar entre las diferentes clases de movimientos. En este sentido, se emplearán algoritmos tiempo-frecuencia avanzados que permitan

descomponer las señales EMG ya sea en sus componentes fundamentales o en las bandas de frecuencia determinadas por las características de la señal.

Una vez calculadas las características estimadas para cada banda de frecuencia, es necesario seleccionar las que más información aporten para distinguir entre las distintas clases de movimientos que en este caso son diferentes flexiones de la mano. Esto se realizará empleando métodos estadísticos que midan el grado de independencia entre ellas. Por último, una vez encontradas las características, se utilizarán para validar un clasificador basado en inteligencia artificial, cuyo propósito es obtener un diagnóstico de forma objetiva y automática.

## CAPÍTULO 2

### FUNDAMENTACIÓN TEÓRICA

#### **2.1. Señales EMG**

La electromiografía (EMG) es un método analítico que mide el potencial de absorción de la membrana muscular. La intención es determinar si el músculo examinado padece de un trastorno en el conducto nervioso que puede derivar en una patología. Este examen se realiza en músculos individuales para localizar y cuantificar los daños después de una enfermedad o accidente (Zurmühle, P. 2017). Como ya se ha mencionado, la electromiografía se utiliza para medir el potencial de acción muscular de una suma de células musculares. El potencial de acción muscular se define como la actividad eléctrica de los músculos.

##### **2.1.1. Adquisición de señales EMG**

El Electromiograma mide los potenciales generados por la contracción muscular. Internamente, los músculos generan voltajes de alrededor de 100 mV cuando se contraen. Estas tensiones son fuertemente atenuadas por el tejido interno y la piel, por lo que son muy pequeñas pero medibles en la superficie de la piel. La señal EMG de superficie típica (sEMG) para músculos grandes como el bíceps tiene una amplitud de aproximadamente

2,1 mV. La señal sEMG contiene frecuencias desde 2 Hz o menos hasta 500 Hz o más (Alva Coras, C.A. 2012).

### **2.1.2. Placa Motora**

La placa motora es aquella estructura que establece una conexión entre una moto-neurona con las fibras musculares, entendiendo que una moto-neurona como una neurona que transmite órdenes motoras desde el sistema nervioso central hacia el sistema nervioso periférico. En esta unión entre el nervio motor y la fibra muscular, es donde se aloja la placa motora, lo que da como resultado la señal de contracción. La función principal de la placa motora es realizar una sinapsis química a través de la reacción de dos proteínas particulares; la miosina y la actina.

La unidad funcional más fundamental de un músculo se denomina unidad motora. Consiste en una motoneurona y todas las fibras musculares que están inervadas por las ramas axonales de la motoneurona. La señal eléctrica que emana de la activación de las fibras musculares de una unidad motora que se encuentran en la vecindad detectable de un electrodo se denomina Potencial de Acción de la Unidad Motora (MUAP). Esto constituye la unidad fundamental de la señal EMG. Se debe de tener en cuenta los muchos factores que influyen en la forma del MUAP (Webster, J. G. 2006).. Algunos de estos son:

- La relación geométrica relativa de las superficies de detección del electrodo y las fibras musculares de la unidad motora en su vecindad.
- La posición relativa de las superficies de detección con respecto a la zona de inervación, es decir, la región donde las ramas nerviosas contactan con las fibras musculares.
- El tamaño de las fibras musculares (porque la amplitud del potencial de acción individual es proporcional al diámetro de la fibra).
- El número de fibras musculares de una unidad motora individual en la vecindad detectable del electrodo.

En la Figura 2.1 se presenta una representación esquemática de la placa motora.

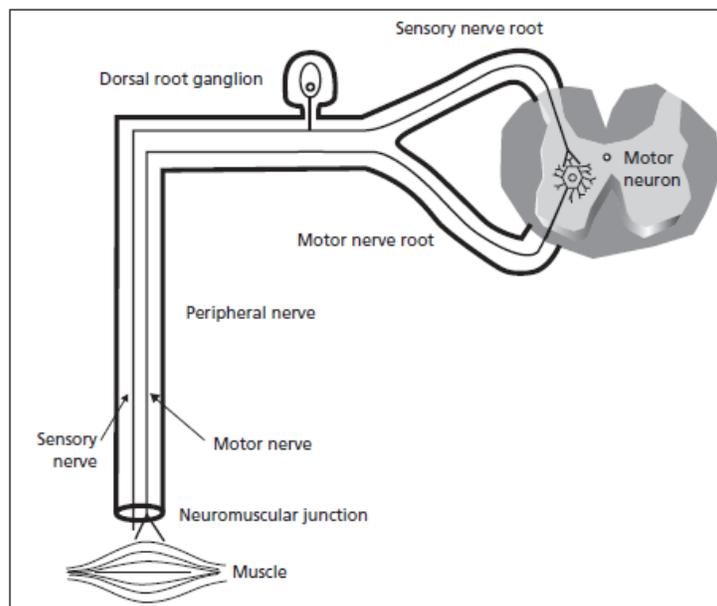


Figura 2.1 Representación esquemática de la placa motora.

Las neuronas motoras se ramifican en fibras musculares a través de su axón, lo que permite enviar señales eléctricas al músculo. Cuando alcance o junte fibras individuales, indica el término de inervación. De acuerdo a la anatomía humana, con la intervención de los nervios músculo cutáneo, axilar, radial y cubital es posible el movimiento de los músculos del antebrazo, ya que esta es la principal zona que permite flexionar y estirar los dedos de la mano. Por ende, los músculos extrínsecos del antebrazo están unidos a las falanges de los dedos por medio de tendones, pero sin músculos. Además, el músculo que permite la extensión de los dedos es el extensor, situado en el antebrazo y accesible por tendones. Los músculos que permiten el movimiento de la mano son el flexor del carpo, el flexor común superficial, el flexor común profundo y el flexor pollicis longus, este último involucrado en la flexión del pulgar, mientras que el flexor común superficial y profundo involucra el movimiento del dedo índice, del dedo medio, del anular y del meñique. En la Figura 2.2 se muestra un esquema de la inervación de los músculos de la mano que permiten este movimiento (Alva Coras, C. A. 2012).

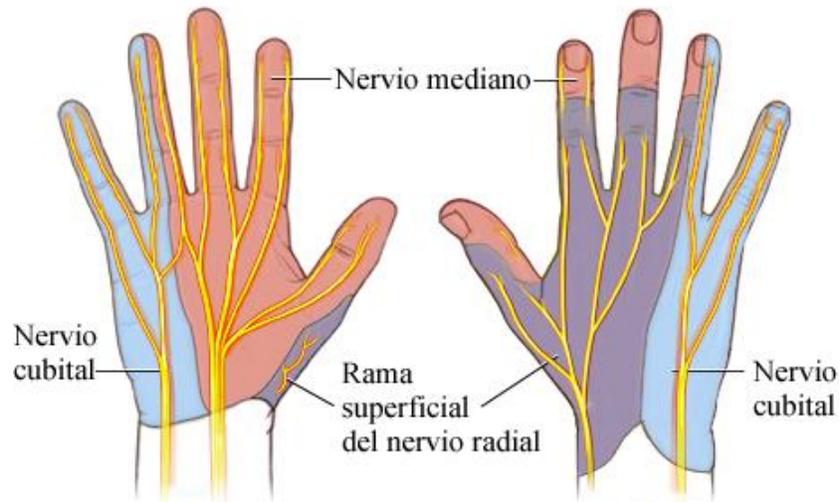


Figura 2.2 (Healthwise 2021).Esquema ilustrado de Inervación de las manos  
[https://content.healthwise.net/resources/13.2/esus/media/medical/hw/s\\_h9991344\\_001.jpg](https://content.healthwise.net/resources/13.2/esus/media/medical/hw/s_h9991344_001.jpg)

### 2.1.3. Sensores

Hay dos categorías de electrodos de superficie: pasivos y activos. Los electrodos pasivos consisten en una superficie de detección conductora (generalmente de metal) que detecta las corrientes de la piel a través de la interfaz entre la piel y los electrodos. El electrodo activo contiene un amplificador electrónico de alta impedancia de entrada en la misma carcasa que la superficie de medición. Esta disposición lo hace menos sensible a la impedancia (por lo tanto, a la calidad) de la interfaz electrodo-piel. La tendencia actual es hacia los electrodos activos. La forma más simple de electrodo pasivo consiste en una placa de plata adherida a la piel. La colocación de un gel o pasta conductora entre los electrodos y la piel mejora mucho el contacto eléctrico. La impedancia se puede reducir aún más eliminando la capa superficial muerta de la piel junto con el aceite protector. Esto se hace mejor frotando suavemente la piel (Webster, 2006).

La falta de equilibrio químico en la unión electrolítica de un metal crea un potencial de polarización que puede verse alterado por cambios de temperatura, acumulación de sudor, cambios en la concentración de electrolitos de la pasta o gel y el movimiento relativo del metal y la piel. No solo el amperaje fluye hacia los electrodos. Es importante tener en cuenta que el potencial de polarización tiene componentes de corriente continua (CC) y

corriente alterna (CA). Al proporcionar una interfaz de intercambio de cloruro reversible con el metal del electrodo, el componente de CA se reduce significativamente.

Tal disposición se encuentra en los electrodos de plata-cloruro de plata. Este tipo de electrodo es muy popular en EMG debido a su peso ligero (0,25 g), pequeño tamaño (<10 mm de diámetro), alta fiabilidad y durabilidad. Cuando se utilizan electrodos en pares, la ganancia de CA cancela el componente de CC del potencial de polarización (Webster, 2006).

El uso y colocación de electrodos es muy importante para la fidelidad, calidad, confiabilidad y detalle de un diagnóstico médico, por lo que el proceso de limpieza de la piel o la dermis donde se utilice debe ser sin vello, por lo que se debe buscar un método que permita para que ningún defecto abandone el área de estudio, impidiendo o alterando así la señal. En la actualidad, se han desarrollado electrodos de superficie activa para eliminar la necesidad de preparación de la piel y medios conductores. Estos se denominan a menudo electrodos "secos" o "sin pasta".

Estos electrodos pueden ser resistentes o estar unidos capacitivamente a la piel. Los electrodos de acoplamiento capacitivo tienen la ventaja de no requerir un medio conductor, pero tienen niveles de ruido inherente más altos. Además, estos electrodos no son fiables a largo plazo porque sus propiedades dieléctricas pueden cambiar en presencia de sudor y erosión dieléctrica. Por estas razones, aún no han encontrado una ubicación para EMG. La electromiografía de superficie se recomienda para estudiar la relación entre la fuerza, el tiempo y las señales sEMG, estudiar la cinética de la superficie, estudiar la neurofisiología de la superficie de un músculo, estudiar la fisiología y establecer una interfaz de interacción entre un individuo y el aparato electromecánico. Para la adquisición de los datos que se usaron en esta tesis, se usaron dos canales de EMG (sensores EMG de la serie Delsys DE 2.x), los cuales son sensores no invasivos inalámbricos de 10 mm de diámetro y maneja un ancho de banda de 10 a 850 Hz y en contraste con otros sensores estos contienen 99.99% de plata.

Como se muestra en la Tabla 2.1, las señales biopotenciales comunes abarcan el rango de CC a 10 kHz. En condiciones ideales, un amplificador de biopotencial con respuesta de banda ancha serviría para la mayoría de las aplicaciones. Sin embargo, la presencia de

potenciales de modo común, polarización de electrodos y otras señales de interferencia a menudo oscurecen la señal de biopotencial que se está investigando. Como tal, la respuesta de frecuencia de un amplificador de biopotencial debe ajustarse al contenido espectral específico que se espera de la aplicación en cuestión.

Electrograma intracardiaco	10Hz-1kHz
EMG superficial.	2-500Hz.
Potenciales de acción de potencial motora.	5Hz-10kHz
Electromiograma de fibra única.	500 Hz–10 kHz
Respuesta galvánica de la piel (GSR): potenciales de batería CC producido por el sudor en los electrodos de la piel.	5 Hz

*Tabla 2.1 Potenciales musculares detectados con electrodos de superficie o electrodos de aguja permanentes.*

## **2.2. Herramientas de descomposición de señales tiempo-frecuencia.**

Existen varias metodologías para extraer características de los datos que permitan clasificar los diferentes tipos de movimientos detectados en las señales EMG. Comúnmente, se pueden clasificar en tres tipos:

- **Análisis en dominio del tiempo:** Este tipo de análisis se utilizan cuando existen variaciones a lo largo del tiempo que son distinguibles en su medición continua y se utilizan para diferenciar un patrón. Una de las ventajas de usar el dominio del tiempo es que se puede implementar en tiempo real, en particular para el diseño del sistema de dispositivos de rehabilitación. Las características asociadas a este análisis pueden ser la raíz cuadrática media (RCM), la medida de desviación estándar y la media de valor absoluto, entre otras (Jali, M. H. et al. 2015).
- **Análisis en dominio de la frecuencia:** En los métodos de frecuencia utiliza herramientas como espectros de energía, transformada corta de Fourier y transformada rápida de Fourier. En señales de EMG se utiliza gran parte de

estos recursos extraer características comúnmente utilizadas en la fatiga muscular y estimación de la fuerza muscular (Too, J. et al. 2017).

- **Análisis en dominio de tiempo-frecuencia:** En general esta metodología requiere de dividir los datos empleados en distintos eventos a lo largo del tiempo para extraer las características necesarias en las señales, de tal manera que la partición sean homogéneos y específicos para su efectividad. Como se ha mostrado en el capítulo anterior, se pueden proporcionar datos sobre el grado de activación del músculo sobre los cambios en la fibra muscular en general y la velocidad de conducción en EMG (Fattah, S. et al. 2012).

En general el análisis de tiempo-frecuencia resulta factible para este trabajo, ya que las señales EMG de los movimientos a analizar pueden visualizarse de mejor manera, lo que genera la metodología desarrollada así, como otros métodos más efectivos para la clasificación de los mismos. Una de estas herramientas para al análisis de tiempo-frecuencia es la transformada Wavelet (WT) (Mitrović et al., 2010).

### **2.2.1. Transformada Wavelet**

Como se menciona la función principal de la WT como otro tipo de análisis tiempo-frecuencia es el de analizar señales no estacionarias mientras que la clásica transformada de Fourier utiliza un intervalo de tiempo reducido y una sola ventana de análisis, la WT usa diversas ventanas segmentadas para altas frecuencias y ventanas largas para bajas frecuencias. En la siguiente figura se hace una comparación entre el desempeño de la dinámica de ventana entre las diferentes transformadas con diferentes tamaños en el dominio del tiempo para distintas frecuencias. En la siguiente Figura 2.3, se puede observar que la WT tiene un mayor desempeño por las diferentes ventanas en el dominio del tiempo (Zhang, D. 2019).

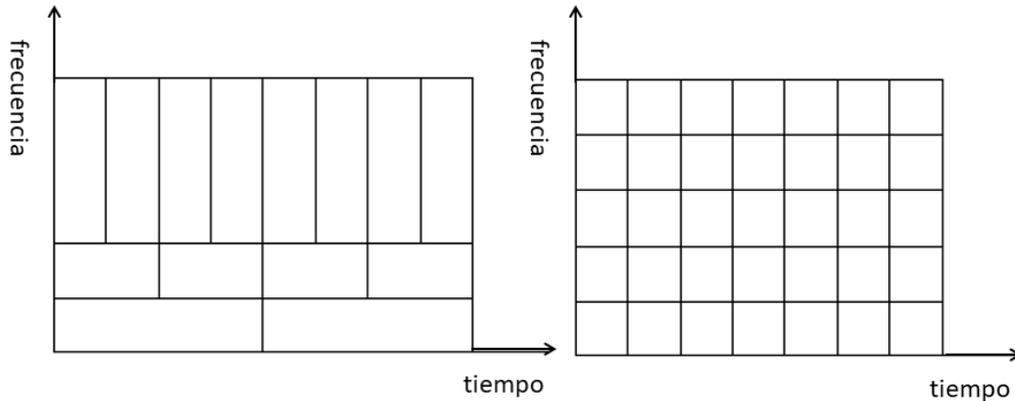


Figura 2.3. Izquierda: El espectro de Wavelet Discreta; Derecha: El espectro STFT.

En un caso diferente a la transformada de Fourier, en donde se utilizan funciones senoidales como funciones base, en la WT se hace uso de funciones ortogonales, mejor conocidas como ondoletas (wavelet) madre. Esto abre pauta para que sea posible investigar diferentes wavelets madre en diferentes señales. Algunas de las ondoletas madre que se emplean son la Daubechies, Coiflets, Haar y Sombrero Mexicano, por mencionar algunas. Las ondoletas analizan y representan una señal con multiresolución, esto es extremadamente útil, porque la resolución más baja representa un resumen y la resolución más alta representa detalles finos de una señal, ambos son esenciales en el análisis y representación de la señal (Zhang, D. 2019). Dentro de la familia de las ondoletas madre Daubechies, existe la db44, esta ondoleta madre en particular, posee características simétricas, así como picos afilados que pueden ser bien acoplados a bioseñales EMG (Rafiee, J et al. 2009, February).

La CWT está definida por la ecuación:

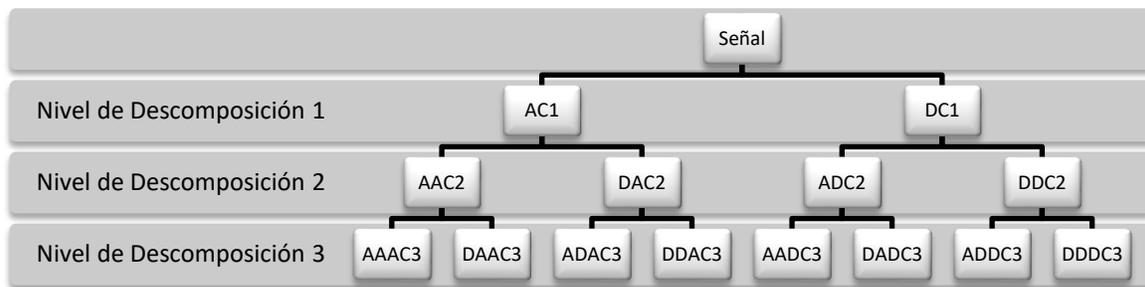
$$\gamma_{\kappa,\chi} \int_{-\infty}^{\infty} f(t)\psi_{\kappa,\chi}^*(t)dt \quad 2.1$$

### 2.2.2. Transformada Wavelet por paquetes

Un banco de filtros es una herramienta iterativa que permite obtener diferentes versiones, desde una señal de entrada. Cada versión permite asociar características de la señal presentes en el dominio del tiempo. Esta herramienta, se utiliza en la transformada wavelet

discreta (DWT) y en la transformada wavelet por paquetes (WPT) para realizar una descomposición usando bancos de filtrado de dos canales a lo largo de una serie de ventanas en distintos niveles jerárquicos que se denomina algoritmo piramidal (Rahman et al.2020).

En contraste con la DWT que solo usa un banco de filtrado que no es uniforme, la WPT es un operador lineal que descompone la señal inicial en dos componentes: coeficientes de detalle (DC, que capturan la información de alta frecuencia y baja escala en la señal original) y coeficientes de aproximación (AC, que son la información de baja frecuencia y alta escala de la señal original), los DC permanecen sin cambios mientras que los AC se descomponen en nuevos DC y AC. Este proceso se repite hasta que se alcanza el nivel de descomposición deseado en la instrucción (Li, T et al. 2016).



La WPT está definida por:

$$W_{j,k}^n(t) = 2^{j/2} \xi^n(2^j t - k) \quad 2.2$$

donde  $j$  representa el coeficiente de escalamiento,  $k$  el coeficiente de traslación,  $n$  el coeficiente de modulación y  $\xi$  los coeficientes de la WT de su respectivo, estos son calculados por la convolución de la wavelet y el filtrado a escala de los coeficientes de la wavelet por paquetes del anterior nivel. Entonces, la WPT, se obtiene a través de las ecuaciones recursivas:

$$W^{2n}(t) = \sqrt{2} \sum_{k=-\infty}^{\infty} h(k)\xi^n(2t - k) \quad 2.3$$

$$W^{2n+1}(t) = \sqrt{2} \sum_{k=-\infty}^{\infty} g(k)\xi^n(2t - k) \quad 2.4$$

Donde  $g(k)$  y  $h(k)$  son los coeficientes de las funciones wavelet. Solo se necesita ejecutar un banco de filtros de dos canales para cada aproximación y detalle. Tanto  $j$  como  $k$  se calculan usando potencias de 2, lo que optimiza el consumo de recursos que los algoritmos emplean para estimar la respuesta (Nikookar, 2013).

### 2.3. Características no lineales

Las señales eléctricas que provienen de las contracciones de la mano muestran un entorno con características no lineales además de dinámicas, es por esto que su acercamiento debe de ser desde un método de la misma índole. Es así que para extraer características de fenómenos no lineales se ha ideado múltiples métodos para poder procesar los datos experimentales sin comprometer la información original, entre los que se destaca la dimensión fractal (FD), los parámetros de Hjorth y medidas de textura.

#### 2.3.1. Fractales

Las dimensiones fractales tienen múltiples definiciones, pero una cosa en común: su valor suele ser un número fraccionario no entero, por lo que esta dimensión se conoce como fractal. Las dimensiones fractales existentes incluyen la dimensión de Hausdorff, la “box dimension”, la dimensión de información, entre otras (Xiao et al., 2005). El concepto de fractal se puede definir como un fenómeno natural auto-similar o un conjunto matemático que muestra un patrón repetitivo en cada escala, esto indica que las propiedades de un conjunto más pequeño de la información no sufrirá pérdida, ya que esta fracción tendrá el mismo patrón como se muestra en la Figura 2.4 (Namazi, 2019).

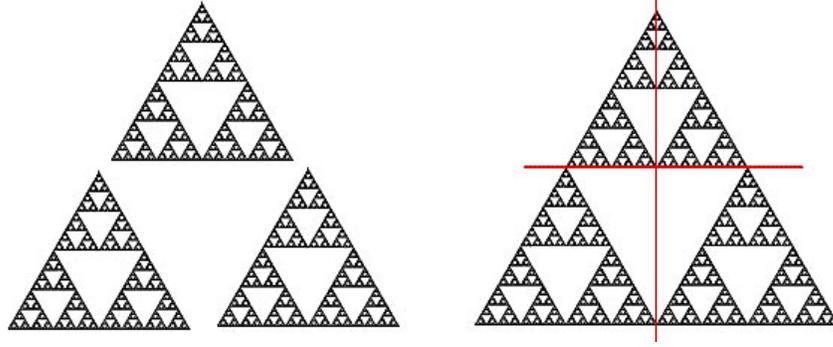


Figura 2.4. Fractal en diferentes niveles jerárquicos.

### 2.3.2. Box Fractal Dimension

Por definición, la aproximación de la BFD se describe de la siguiente manera:

$$BFD \cong - \frac{\ln \left( \sum_{i=1}^{N-1} \frac{|x_{i+1} - x_i|}{\Delta t} \right)}{\ln(\Delta t)} \quad 2.5$$

donde,  $x_i$  es una función en el tiempo, con  $N$  número de muestras, en un intervalo de tiempo  $\Delta t$  (Piña-Vega et al., 2021).

### 2.3.3. Katz

Para una señal en el tiempo  $(x_i, y_i)$  con  $N$  número de muestras, la FD de Katz (KFD), se define como:

$$KFD = \frac{\log(N)}{\log(N) + \log\left(\frac{d}{L}\right)} \quad 2.6$$

donde  $d$  está definida como la mayor distancia entre la primera muestra y las subsecuentes, así como  $L$  que es la distancia Euclidiana entre puntos sucesivos de la misma señal (Katz, 1988; Piña-Vega et al., 2021); dichas señales se definen por:

$$L = \sum_{i=2}^N \sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2} \quad 2.7$$

$$d = \max((x_i - x_{i-1})^2 + (y_i - y_{i-1})^2) \quad 2.8$$

### 2.3.4. Higuchi

Para poder implementar la FD de Higuchi (HFD), se debe construir una nueva serie de tiempo ( $X_k^m$ ) proveniente de nuestra señal, de numero de muestras  $N$ , de origen; está, definida de la siguiente manera:

$$X_k^m = X(m), X(m+k), X(m+2k), \dots, X\left(m + \left[\frac{N-m}{k}\right] \cdot k\right) \quad 2.9$$

donde  $m$  es la muestra inicial de tiempo y  $k$  el intervalo entre dos muestras sucesivas. Para cada secuencia  $X_k^m$  el promedio de longitud  $L$  es calculado con la siguiente ecuación:

$$L_m(k) = \frac{\left\{ \left( \sum_{i=1}^{\left[\frac{N-m}{k}\right]} |X(m+ik) - X(m+(i-1) \cdot k)| \right) \left( \frac{N-1}{\left[\frac{N-m}{k}\right]} \cdot k \right) \right\}}{k} \quad 2.10$$

Posteriormente, se calcula la longitud promedio total, definida a por:

$$L(k) = \sum_{m=1}^k L_m(k) \quad 2.11$$

De esto se obtiene que:

$$\ln[L(k)] \propto D \ln\left(\frac{1}{k}\right) \quad 2.12$$

donde la pendiente  $D$  es considerada el valor de la HFD de una señal en particular (Higuchi, 1988).

### 2.3.5. Sevcik

El método FD de Sevcik (SFD) es considerado una variación de la KFD, pero en este caso, la señal de tiempo es normalizada como se muestra a continuación:

$$x_i^* = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad 2.13$$

$$y_i^* = \frac{y_i - \min(y)}{\max(y) - \min(y)} \quad 2.14$$

la SFD de la señal previamente normalizada es estimada por la siguiente ecuación:

$$SFD = \frac{\log(L) + \log(2)}{\log(2 * (N + 1))} \quad 2.15$$

donde  $L$  es la distancia Euclidiana entre los puntos sucesivos previamente normalizados:

$$L = \sum_{i=2}^N \sqrt{(x_i^* - x_{i-1}^*)^2 + (y_i^* - y_{i-1}^*)^2} \quad 2.16$$

### 2.3.6. Medias de Textura

La textura es una de las características más utilizadas en el procesamiento de imágenes y el reconocimiento de patrones para detectar o identificar objetos confiables en una escena. La textura se define como un patrón particular y generalmente repetido en la superficie de un objeto dado, se considera esencialmente como una propiedad dentro de una área delimitada. Sin embargo, algunas de estas funciones no son completamente autónomas y el consumo de memoria es importante. SDH, por otro lado, es una alternativa a GLCM, donde SDH puede usarse para reducir los requisitos de memoria y el tiempo computacional. El método SDHs, propuesto por primera vez por (Unser, 1986), es un poderoso método de análisis de características de textura que permite obtener información importante de textura de una manera simplificada pero optimizada (Ibarra et al., 2010).

Para este trabajo se toma la media y la correlación de las medidas de textura la cual se escriben la siguiente forma.

$$\frac{1}{2N} \sum_k \sum_l I_s(k, l) = \mu \quad 2.17$$

Donde  $I_s(k, l)$  representa el histograma de suma en la cuadrícula rectangular, es decir, el número de veces que un nivel de gris  $i$  está presente en la imagen se suma el siguiente elemento en el dominio  $D$ , el cual es un subconjunto de índices que especifica una región a analizar,  $k$  indica largo de la imagen y  $l$  el ancho o viceversa. En el caso de la señal, representa los datos dentro de la muestra en el dominio del tiempo de manera lineal. Esta suma se divide entre dos veces  $N$  que representa la longitud de la señal (Ibarra et al., 2010).

La correlación por otro lado se representa de la siguiente manera:

$$\frac{1}{2N} \sum_k \sum_l (I_s(k, l) - 2\mu)^2 - \sum_k \sum_l (I_d(k, l))^2 \quad 2.18$$

En este algoritmo se añade la imagen de diferencia  $I_d$  que representa el histograma de resta en la cuadrícula rectangular, es decir, el número de veces que un nivel de gris  $i$  está presente en la imagen se resta el siguiente elemento en el dominio  $D$  (Ibarra et al., 2010).

### 2.3.7. Parámetros de Hjorth

Los Parámetros Hjorth se definen como métricas de propiedades estadísticas de señales que se encuentran en el dominio del tiempo, así las se las ubican también dentro de esta clasificación, pese a que sus resultados pueden interpretarse en el dominio de la frecuencia. Se dividen en tres distintos parámetros: actividad, movilidad y complejidad (Benítez, 2018).

- **Actividad:** Representa la potencia de la señal. Se calcula con la siguiente ecuación.

$$Ax = \frac{\sum_{t=1}^T (x(t) - \mu)^2}{T} \quad 2.19$$

Donde,  $x(t)$  representa los datos de la señal en el tiempo,  $T$  representa el número total de datos en la señal y  $\mu$  representa la media de la señal.

- **Movilidad:** Se refiere a la proporción de desviación estándar del espectro de potencia. Se calcula mediante:

$$Mx = \sqrt{\frac{\text{var}(x'(t))}{\text{var}(x(t))}} \quad 2.20$$

Donde,  $\text{var}(x'(t))$  representa la varianza de la primera derivada de la señal analizada y  $\text{var}(x(t))$  la varianza de la señal analizada.

- **Complejidad:** Analiza la similitud de la señal al compararla con una sinusoidal pura, cuyo resultado tiende a 1 cuando la similitud es mayor. Se calcula con la siguiente ecuación.

$$Cx = \frac{M(x'(t))}{M(x(t))} \quad 2.21$$

Donde,  $M(x'(t))$  representa la movilidad de la primera derivada de la señal analizada y  $M(x(t))$  la movilidad de la señal analizada.

### 2.3.8. ANOVA

El propósito general de la función ANOVA es tabular la variabilidad de un ensayo en grupos para representar la variabilidad de los mismos por separado. De este modo se puede ejemplificar si dentro de estos grupos existe una media con un diferencial evidente, se puede identificar una característica.

Es una herramienta paramétrica que hace varias suposiciones sobre la distribución de los datos analizados.

- Se toman muestras de cada grupo de distribución normal.
- Cada punto de un mismo grupo es independiente de los demás y se distribuyen muestras aleatorias.
- Las varianzas de los grupos son similares.

### 2.3.9. ANOVA no Paramétrico

La prueba Kruskal-Wallis también es una prueba no maestra llamada "ANOVA en vía de rangos" o "ANOVA no paramétrico", se puede usar para determinar si existe una diferencia estadística entre dos o más grupos de variables independientes en el sistema a analizar. Esta prueba no le indica que los grupos en comparación existen desviaciones, este indica que grupos diferentes entre sí, se necesitan más de 5 muestras para cada grupo y están determinadas por la siguiente ecuación:

$$KW = \frac{12}{n(n+1)} \left( \frac{T_1^2}{n_1} + \frac{T_2^2}{n_2} + \dots + \frac{T_k^2}{n_k} \right) - 3(n+1) \quad 2.27$$

Donde  $n_i$  es el tamaño de las muestras,  $n$  es el número total de muestras y  $T_i$  son las sumatorias de las muestras. Para conocer el valor-P asociado a ese resultado.

### 2.3.10. Valor-P

El valor P es uno de los resultados del análisis ANOVA que indica la probabilidad del modelo estadístico de que, cuando la hipótesis nula es verdadera, la sumatoria debe ser igual o mayor que el resultado observado. Por lo tanto, el valor P indica cuán inconsistentes son los datos con un modelo estadístico particular. Cuanto menor sea el valor p, mayor será la inconsistencia entre los datos (Sohal, H. et al. 2018).

## 2.4. Redes Neuronales

Las redes neuronales dentro del contexto del procesamiento de señales se utilizan como una herramienta de estadísticas para modelos no lineales. Una red neuronal artificial (o simplemente red neuronal) consta de una entrada capa de neuronas (o nodos, unidades), una o dos (o incluso tres) capas ocultas de neuronas, y una capa final de neuronas de salida (Guresen et al., 2011).

El perceptrón multicapa (MLP) es un tipo notable de red neuronal artificial que se usa a menudo para tareas de reconocimiento de actividad. Son capaces de modelar relaciones no

lineales complejas y proporcionan un enfoque alternativo para el reconocimiento de patrones. Las redes neuronales requieren altas capacidades computacionales que habían restringido su uso anteriormente, sin embargo, debido a los recientes avances en tecnología, se están explorando arquitecturas más complejas con potencial para ofrecer un mejor rendimiento y soporte (Irvine, N et al. 2019).

#### **2.4.1. Arquitectura y topología**

Los perceptrones multicapa son un tipo de red neuronal de naturaleza heteroasociativa con una arquitectura unidireccional formada por grupos segmentados en planos llamados capas. Consisten en unidades básicas de procesamiento computacional llamadas neuronas que operan en paralelo y sus entradas se toman de fuentes externas. Es decir, como cualquier otro tipo de Deep Learning su función es hallar una función  $f(x)$  tal que a través de un dato de un dato o en este caso un vector de entrada  $x$  sepa categorizar una salida  $y$ . Las redes heteroasociativas requieren la presencia de múltiples capas y se caracterizan por vincular pares de estímulos mediante la aplicación de procesos de aprendizaje controlados por agentes externos (Rahmer, et al., 2020).

La composición de este tipo de red es un conjunto de capas que a su vez están formadas por neuronas, la cantidad de este conjunto dependerá de la profundidad que tenga la propia red (Arévalo González, D. 2021). La primera capa se conoce como capa de entrada que recibe los datos del vector de entrada, estos datos son modificados por los pesos ( $W$ , que modifican la entrada según los parámetros establecidos), seguida de capas intermedias denominadas como capas ocultas, las neuronas de esta capa reciben información de otras neuronas artificiales y señales de entrada y salida permanecen dentro de la red. Por ultimo, en la capa de salida las neuronas reciben la información procesada y la devuelven al exterior (Morera Munt et al., 2018). En la Figura 2.5 se muestra una RN con la capa de entrada, dos capas ocultas y una capa de salida.

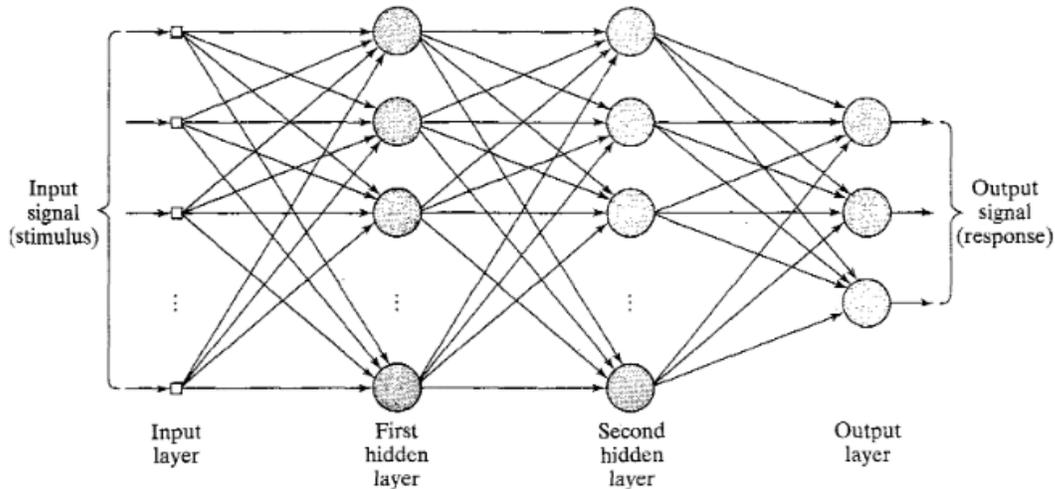


Figura 2.5 Perceptrón Multicapa con 2 capas ocultas.

A su vez, existen tres diferentes tipos de arquitecturas dentro de las redes neuronales entre las que se destacan:

- El Perceptrón simple, (Rosenblatt, F. 1958). Se trata del modelo más sencillo de redes neuronales artificiales, ya que consta de una sola capa de neuronas con una única salida y.
- Red multicapa: se caracteriza por tener una o más capas intermedias a las cuales se les llama “capas ocultas”, como se muestra en la Figura 2.5 (Arévalo González, D. 2021).
- Red recursiva: Es una red con retroalimentación, en donde algunas de las salidas están conectadas a las entradas (Casas, 2020).

En este trabajo, se optó por una arquitectura de dos capas: una oculta y otra de salida. El número de entradas se establece por el grupo de funcionalidades a utilizar en el procesamiento previo del siguiente capítulo, el número de neuronas en la capa oculta se encontró a través de la experimentación, variando de entre diez a quince neuronas, y el número de neuronas en la salida está determinado por las tres flexiones de los dedos de la mano seleccionadas.

### **2.4.2. Aprendizaje supervisado**

Para este tipo de problemas, los datos ingresados al sistema se identifican mediante una etiqueta. El propósito de este tipo de algoritmo es asignar un valor de etiqueta a cada instancia. Más técnicamente, el sistema monitoreado necesita obtener la distribución prevista  $p(t|x)$  con el valor de etiqueta  $t$  dada la entrada  $x$ . Puede distinguir entre diferentes problemas dependiendo de la naturaleza de su entrada. Como en el caso de este proyecto, la clasificación, si es que la etiqueta toma valores discretos y regresión si la etiqueta toma valores continuos, etc (Arévalo González, 2021). Además del aprendizaje supervisado, existen el aprendizaje no supervisado y el aprendizaje de refuerzo.

#### **2.4.2.1. Algoritmo de entrenamiento**

Los modelos red multicapa han mostrado buenos resultados en la clasificación de señales EMG superficial, por lo que han sido elegidos para realizar la tarea de diferenciación de las flexiones de la mano. Las redes de aprendizaje supervisado se caracterizan por tener a la entrada datos previamente analizados para obtener una salida deseada. La información de entrada es llamada “información de entrenamiento” y sus correspondientes salidas son llamadas “objetivo”. La estructura del modelo de Red Neuronal Artificial que se construye este caso consta de: Un vector de entradas  $X = [x_1, x_2, x_3 \dots, x_n]$  de  $n$  componentes, provenientes del exterior, de un conjunto de ponderaciones sinápticas  $W = [w_1, w_2, w_3 \dots, w_n]$  denominados pesos, reflejan la magnitud de la interacción entre la neurona presináptica y post-sináptica, estos son actualizados mediante un proceso de aprendizaje; también incluye una regla de propagación que entre neuronas vecinas que consiste en la combinación lineal de las entradas y los pesos sinápticos. La red también está constituida por una Función de salida asociada a cada unidad de procesamiento que modifica el estado de activación actual para proporcionar una señal de salida. El vector de salidas es  $Y = [y_1, y_2, y_3 \dots, y_n]$  (Perdomo et al., 2021). Se debe hacer la anotación de que la función de activación/transferencia del perceptrón multicapa debe cumplir estrictamente ciertas condiciones: Debe ser continua, diferenciable y no decreciente.

Para la red neuronal multicapa se utiliza un método conocido como “backpropagation” o retropropagación. En el caso de la RN multicapa, el error es una complicada función compuesta de los pesos sinápticos de las capas previas. Utilizando la regla de la cadena de cálculo diferencial, la retropropagación calcula los gradientes del error en términos de suma

de producto de gradientes locales resultante, es decir, estima si la función del error es ascendente o descendente así como las diferentes rutas que se pueden tomar desde una neurona hasta la salida de tal manera que se reduzca el error. Este algoritmo consta de dos fases, avance y retroceso. En la primera fase se calculan los valores de salida y las derivadas locales de las distintas neuronas, mientras que en la segunda fase se acumula el producto de estos valores locales en dirección de la capa de salida. (González, 2021).

- Fase de avance: En esta etapa, las entradas para una instancia de entrenamiento, se alimentan en la RN. Esto da como consecuencia, una serie de cálculos hacia adelante a través de las capas ocultas, utilizando el grupo de pesos sinápticos en ese momento. La salida final prevista se puede equiparar con la de la fase de entrenamiento y se deriva la función del error respecto a la salida. La derivada estimará el gradiente de la función del error en relación a los pesos sinápticos, esto se repetirá en cada una de las capas en la etapa de retroceso.
- Fase de retroceso: El primordial objetivo esta etapa, es el aprender el gradiente de la función de error en relación a los diferentes pesos sinápticos utilizando la regla de la cadena. Dichos gradientes, son empleados para actualizar los pesos. Es así que los gradientes son logrados de reversa, en otras palabras, en dirección opuesta a la salida. Es por eso que a esta fase se le conoce como fase de retroceso.

En resumen, El primer paso es propagar la entrada de las capas ocultas:

$$a^0 = p \quad 2.28$$

$$a^{m+1} = f^{m+1}(W^{m+1}a^m + b^{m+1}) \text{ para } m = 0, 1, \dots, M - 1 \quad 2.29$$

$$a = a^M \quad 2.30$$

El segundo paso es propagar las sensibilidades de la red hacia atrás a través de la red:

$$s^M = -2F^M(n^M)(t - a) \quad 2.31$$

$$s^m = F^m(n^m)(W^{m+1})^T s^{m+1}, \text{ para } m = M - 1, \dots, 2, 1 \quad 2.32$$

Finalmente, se actualizan los pesos y las bias:

$$W^m(k + 1) = W^m(k) - \alpha s^m (a^{m-1})^T \quad 2.33$$

$$b^m(k + 1) = b^m(k) - \alpha s^m \quad 2.34$$

Siendo  $\alpha$  la tasa de aprendizaje,  $s$  la sensibilidad de cierta capa ante la entrada,  $M$  el número de capa,  $t$  el valor objetivo y  $F$  la función de transferencia derivativa (Du, et al., 2006).

## CAPÍTULO 3 METODOLOGÍA

### 3.1. Metodología Propuesta

A continuación, en la Figura 3.1, se muestra la metodología para el procesamiento de señales de EEG para la detección y clasificación de señales de los dedos de la mano.

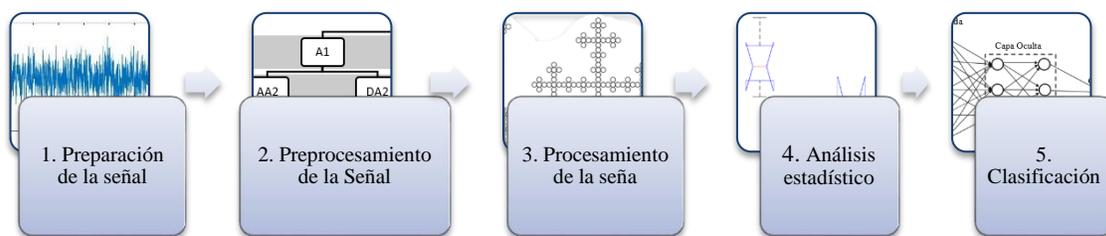


Figura 3.1. Metodología propuesta.

Como se puede observar en la figura, la metodología propuesta consta de 5 pasos principales, que son:

- 1. Preparación de la señal:** Se ordena la base de datos identificando el nombre de las muestras que correspondan a cada movimiento, cada muestreo esta identificado por su inicial en ingles de manera independiente y combinados con el dedo pulgar por lo cual para esta tesis se decidió trabajar con las muestras de los movimientos de tres dedos que se mueven de manera independiente serán el dedo Indice, Medio y Meñique.
- 2. Preprocesamiento de la señal:** A continuación se toman las archivos de los movimientos mencionados, cada uno de estos archivos tienen consigo seis muestras del mismo movimiento con dos señales en cada muestra, dando como resultado 12 señales por movimiento. A todas las señales seleccionadas se les aplica la WPT con un nivel 4 de descomposición y con una Ondoleta madre Daubechies 44, para tener en total 16 descomposiciones de tiempo-frecuencia.
- 3. Procesamiento de la señal:** Se aplican diferentes técnicas de extracción de características a las descomposiciones del paso anterior. En este trabajo se utilizan los metodos de FD como el metodo de Box Counting Dimensión, algoritmo de Katz, algoritmo de Sevcik, medidas de textura y los parámetros de Hjorth. Por consiguiente, se obtiene un solo valor de cada vector de la descomposición de Wavelet Packet de cada movimiento, para esta tesis se hace un estudio preliminar para situar los nodos más discriminantes en los detalles y aproximaciones en el cuarto nivel de descomposición, por medio de estos algoritmos se examina el nodo donde existe mas discriminación en los valores de cada señal y con que algoritmo es más evidente mediante un analisis grafico.
- 4. Analisis estadístico:** Una vez identificados los grupos de fractales que resultan más discriminantes entre sí se evalúa por medio de un análisis estadístico de la varianza (ANOVA) no paramétrico que grupos son los mejores para su estudio de acuerdo a su valor P. De este análisis se selecciona que tipo de FD o parámetro resulta en un mayor diferencial entre los tres movimientos para facilitar su clasificado a través de un algoritmo de inteligencia artificial.

- 5. Clasificación:** Como ultimo paso conociendo los resultados de los mejores grupos en el analisis ANNOVA se hace el diseño de un Red neuronal multicapa probando con diferente numero de neuronas y de capas ocultas para la clasificación de los tres movimientos de la mano, se hace una partición porcentual entre los datos de entrenamiento y de validación.

### **3.2. Descripción de la base de datos empleada**

La base de datos empleada, llamada “A large electroencephalographic motor imagery dataset for electroencephalographic brain computer interfaces”, provenientes de la base de datos de acceso publico proporcionada por Rami N. Khushaba, Sarath Kodagoda, Maen Takruri y Gamini Dissanayake de la universidad de Sydney, publicada en Expert Systems with Applications en 2021 (<https://www.rami-khushaba.com/electromyogram-emg-repository.html>).

#### **3.2.1. Participantes y procedimientos**

Se describen los datos de ocho sujetos, seis hombres y dos mujeres, con edades comprendidas entre 20 y 35 años para realizar los movimientos de dedos requeridos. Todos los sujetos tenían extremidades normales y no presentaban trastornos neurológicos o musculares. Todos los participantes dieron su consentimiento informado antes de participar en el estudio. Los sujetos se sentaron en un sillón, con el brazo apoyado y fijo en una posición para evitar el efecto de las diferentes posiciones de las extremidades en las señales EMG generadas (Scheme, Founger, Stavdahl, Chan y Englehart, 2010).

#### **3.2.2. Adquisición de los datos**

Los datos de EMG se recopilaron utilizando dos canales de EMG (sensores EMG de la serie Delsys DE 2.x) y se procesaron con Bagnoli Desktop EMG Systems de Delsys Inc. Se aplicó una interfaz de piel adhesiva de 2 ranuras en cada uno de los sensores para pegar firmemente los sensores a la piel. Se utilizó un electrodo de referencia adhesivo conductor (Dermatode Reference Electrode) en la muñeca de cada sujeto.

Las señales EMG recolectadas de los electrodos se amplificaron usando un amplificador Delsys Bagnoli-8 a una ganancia total de 1000. Un convertidor de analógico a digital de 12 bits (National Instruments, BNC-2090 ) se utilizó para muestrear la señal a 4000 Hz; Posteriormente, los datos de la señal se adquirieron utilizando el software de adquisición Delsys EMGWorks. A continuación, las señales de EMG se filtraron en paso de banda entre 20 y 450 Hz con un filtro de muesca implementado para eliminar la interferencia de línea de 50 Hz. Se implementaron diez clases de movimientos de dedos individuales y combinados que incluyen: la flexión de cada uno de los dedos individuales, es decir, pulgar (T), índice (I), medio (M), anular(R), meñique (L) y la flexión combinada de pulgar-índice (T-I), pulgar-medio (T-M), pulgar-anular (T-R), pulgar-pequeño (T-L) y, finalmente, el cierre de la mano (HC) como se muestra en la cifras dentro del conjunto de datos (Khushaba, R.et al 2012).

Sabiendo que el electromiograma está compuesto por una serie de ondas eléctricas generadas por los músculos del antebrazo con una frecuencia de entre 20 y 450 Hz con un filtro de muestra implementado para eliminar la interferencia de línea de 50 Hz.

Es importante mencionar que los principios éticos en los que se basa el presente trabajo de tesis son (CIOMS & OMS, 2002):

# CAPÍTULO 4

## EXPERIMENTACIÓN Y RESULTADOS

### 4.1. Resultados obtenidos

En esta sección se describe en detalle la metodología utilizada para la base de datos descrita en el capítulo anterior, así como los resultados de cada etapa. Recordando que se utilizaron los archivos de las señales correspondientes al dedo índice, al dedo medio y al dedo meñique. Para esta metodología también se usó un estudio preliminar para comparar gráficamente los datos y así descartar los fractales que no fuesen lo suficientemente efectivos.

#### 1. Preparación de la señal.

Haciendo referencia al capítulo anterior, para cada paciente, se hicieron seis muestras de cada movimiento de las cuales cada una contiene 2 señales con una frecuencia de muestreo de 4000 Hz (con duración de 5 segundos). Esta misma clasificación se repite para 8 sujetos de entre 20-35 años, de los cuales 6 eran hombres y 2 son mujeres. En esta primera etapa se extraen las señales correspondientes a los movimientos sugeridos, las cuales están marcadas por: índice (I), medio (M), anillo (R), meñique (L). Se toman las señales completas de cada movimiento de las muestras de los primeros 6 pacientes y se descartan las flexiones combinadas de los dedos porque alteran el objetivo de diferenciar los movimientos de los dedos por separado. En Figura 4.1 se muestra la representación de los movimientos seleccionados y su representación gráfica de las señales producidas en Matlab.



Figura 4.1. Representación gráfica de las flexiones de los dedos estudiadas.

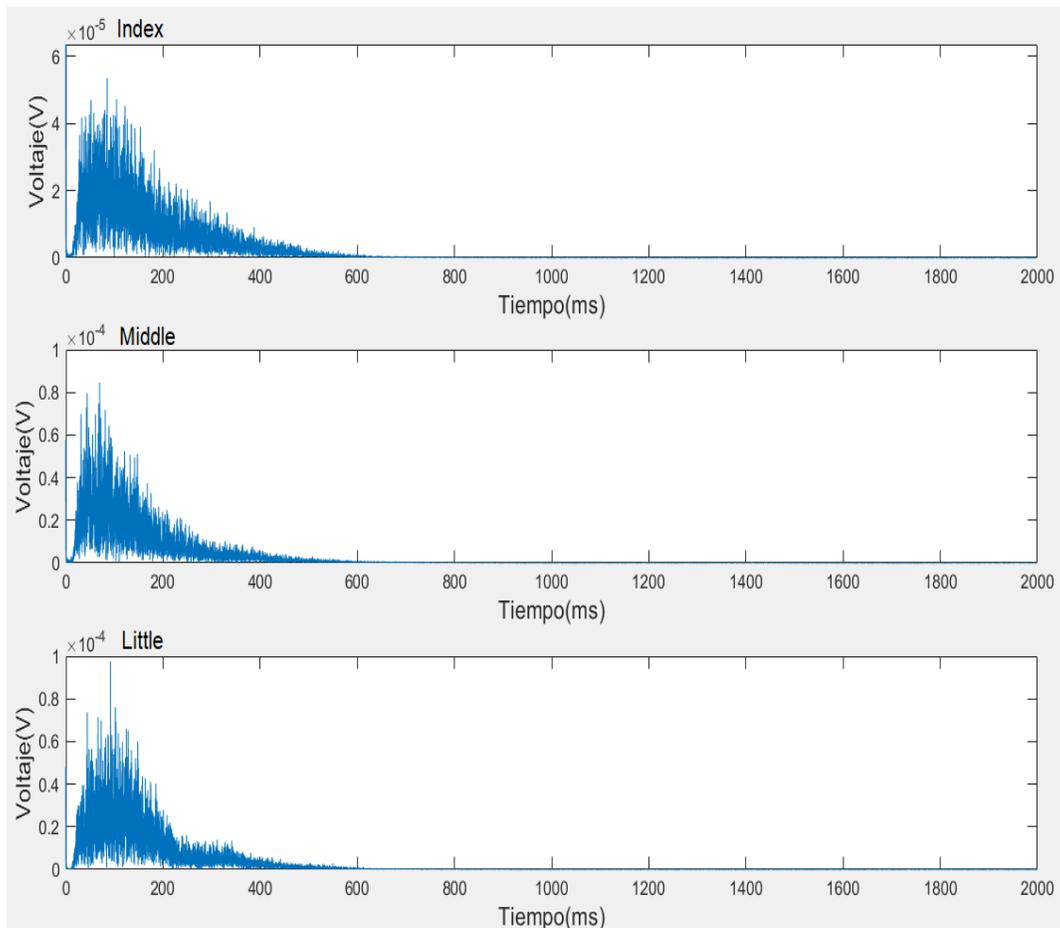


Figura 4.2. Representación grafica de la señales de las flexiones seleccionadas.

## 2. Descomposición Wavelet.

A cada señal de movimiento se le aplicó la WPT con un nivel 4 de descomposición con el objetivo de tener varias ventanas de frecuencia de la señal con la menor pérdida de información, ya que un nivel mayor a este genera problemas en la modulación de la señal que puede representar una alteración en el análisis por la reducción en el ancho de banda. Consecuentemente, se usa la ondoleta Daubechies 44 a todas las señales de los movimientos identificando cada señal con su nombre y número de pacientes (N): Index\_N (dedo Índice), Middle\_N (dedo Medio), Little\_N (dedo Meñique). De cada señal se obtienen 16 descomposiciones wavelet. Con esta transformada se puede ver claramente dónde puede existir información relevante que sea diferenciadora entre los movimientos, por lo que es necesario un análisis matemático para tener la certeza de que exista una característica que distinga las

descomposiciones. En la Figura 4.3 se pueden observar las descomposiciones de una de las señales de cada flexión.

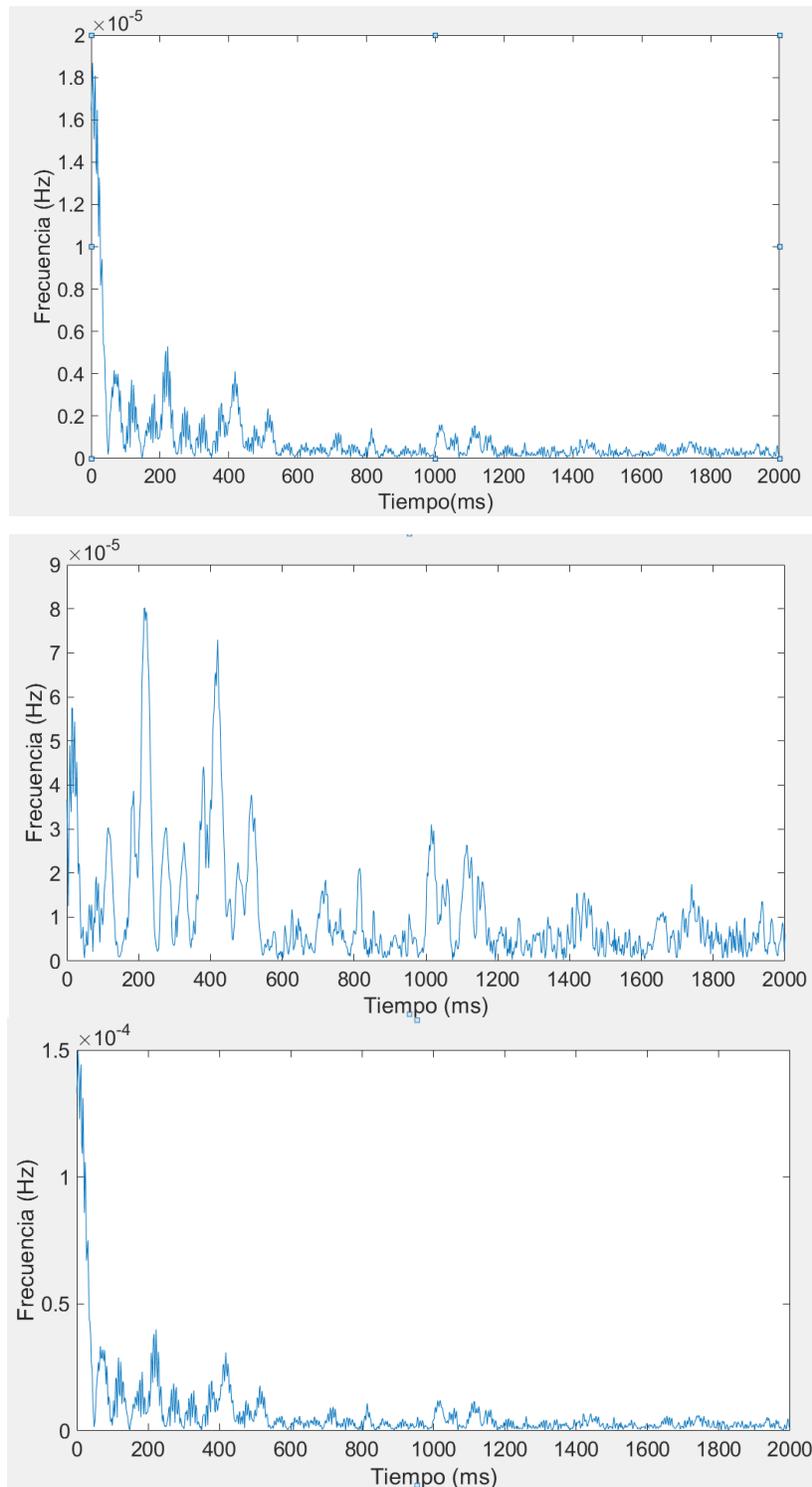


Figura 4.3 Descomposiciones de una de las señales de cada flexión (I), (M), (L).

### 3. Procesamiento de la señal.

En este paso se aplicaron diferentes algoritmos de DF y medidas de textura para comparar los 16 nodos de descomposición wavelet de cada señal EMG. De esta manera, se obtuvo un archivo de tipo estructura para cada uno de los diferentes tipos de medidas de textura o DF para cada movimiento teniendo un total de 48 valores por paciente. Adicional a esto, se hace un estudio preliminar entre los diferentes algoritmos de DF y medidas de textura para comparar entre los 16 nodos de descomposición wavelet de cada movimiento a través de un gráfico, este paso ayuda a descartar de manera contundente los algoritmos que no muestren condiciones necesarias para la extracción de características. En la tabla 4.1 se muestran los valores de las diferentes DF y medidas de textura seleccionadas en sus primeros 10 nodos de descomposición del movimiento Little.

Tabla 4.1 Valores de las diferentes DF y medidas de textura seleccionadas en sus primeros 10 nodos de descomposición del movimiento Index.

Nodo	BFD	FDK	FDH	FDS	TFM	TFC	HPA	HPM	HPC
1	-1.6835	1.4471	2.05903615	1.7607	9.29E-05	-1.01E-09	2.59E-06	1.4952	1.0974
2	-1.6245	1.4536	2.11951815	1.7796	0.000152	1.66E-09	4.31E-07	1.6825	1.0933
3	-1.6490	1.4476	1.88586228	1.7036	-4.53E-05	-4.10E-10	8.64E-08	1.2463	1.3384
4	-1.6536	1.4541	2.11640525	1.7412	1.42E-05	1.04E-12	1.69E-08	1.6573	1.0918
5	-1.6726	1.4434	1.72451233	1.6922	-5.86E-06	-9.63E-15	2.40E-09	1.0451	1.5267
6	-1.6582	1.4532	2.12065237	1.7319	1.61E-06	-1.56E-12	2.21E-10	1.6684	1.092
7	-1.6390	1.4385	1.84222065	1.6242	5.43E-07	6.96E-15	2.96E-11	1.1524	1.3862
8	-1.5512	1.4348	2.05708577	1.5698	1.31E-07	-6.81E-14	5.41E-12	1.5896	1.2193
9	-1.5567	1.4363	2.02027924	1.5798	4.31E-07	-8.50E-14	1.98E-12	1.3276	1.1766
10	-1.4231	1.4211	2.03652442	1.5292	-1.26E-07	-1.40E-14	8.96E-13	1.6028	1.1746

Una vez descartando los algoritmos que no presentan cambios gráficamente, se hace el acomodo de las descomposiciones por movimiento para 3 pacientes, los cuales cada uno cuenta 6 pruebas por movimiento. Entonces, se crea una matriz con los datos acomodando el tipo de movimiento, la FD o parámetro de medición y el número nodo. Por tanto, se obtienen 18 vectores de 16 valores con información relevante de acuerdo con el nivel de descomposición (4 renglones en total por cada extractor de características seleccionado). En la Tabla 4.2 se muestran los valores de FDK de las 6 pruebas en el sujeto 3 para movimiento Index. Así mismo, en la Tabla 4.3 se muestran los valores de FDK de las 6 pruebas en el sujeto 3 para el movimiento Middle y en la Tabla 4.4 se muestran los valores de FDK de las 6 pruebas en el sujeto 3 para el movimiento Little.

Tabla 4.2 Valores de FDK de las 6 pruebas en el sujeto 3 para el movimiento Index.

<b>Nodo</b>	<b>Prueba 1</b>	<b>Prueba 2</b>	<b>Prueba 3</b>	<b>Prueba 4</b>	<b>Prueba 5</b>	<b>Prueba 6</b>
<b>1</b>	1.44265741	1.44263094	1.00734451	1.44068227	1.42547309	1.45527375
<b>2</b>	1.44760326	1.44020218	1.32208971	1.45497534	1.4373628	1.45290788
<b>3</b>	1.44293528	1.41082846	1.268692	1.43748882	1.42486841	1.42476538
<b>4</b>	1.43989887	1.43314288	1.32441692	1.44643066	1.44270994	1.45415904
<b>5</b>	1.41875113	1.4230644	1.31671907	1.43463979	1.4112674	1.43051241
<b>6</b>	1.42778259	1.38572733	1.31209547	1.45487801	1.41654582	1.45879543
<b>7</b>	1.40960227	1.33953933	1.31240862	1.40496187	1.38679249	1.42168027
<b>8</b>	1.38135651	1.35126133	1.28515136	1.422695	1.36346286	1.42820877
<b>9</b>	1.39870246	1.27265259	1.32095271	1.42587951	1.36814935	1.44577338
<b>10</b>	1.38247176	1.32581981	1.32066211	1.39829133	1.34174883	1.41913393
<b>11</b>	1.36068651	1.27024073	1.3190249	1.37776347	1.26115928	1.40075649
<b>12</b>	1.38011152	1.31775814	1.30750111	1.39699989	1.3265285	1.40143148

<b>13</b>	1.37373393	1.32631172	1.30298876	1.39057462	1.32020067	1.40833877
<b>14</b>	1.40342612	1.27464055	1.32820953	1.41470652	1.29386866	1.41762206
<b>15</b>	1.4023128	1.27772158	1.32043223	1.42183731	1.29667123	1.43000128
<b>16</b>	1.45801592	1.25926153	1.34222341	1.45582801	1.31457809	1.45186125

Tabla 4.3 Valores de FDK de las 6 pruebas en el sujeto 3 para el movimiento Middle.

<b>Nodo</b>	<b>Prueba 1</b>	<b>Prueba 2</b>	<b>Prueba 3</b>	<b>Prueba 4</b>	<b>Prueba 5</b>	<b>Prueba 6</b>
<b>1</b>	1.43601728	1.44885193	1.45706206	1.45936249	1.43997573	1.45137416
<b>2</b>	1.44565157	1.43945033	1.45976789	1.44438911	1.4596845	1.45502932
<b>3</b>	1.44281818	1.42260099	1.42876408	1.44072254	1.42294795	1.43889841
<b>4</b>	1.4655013	1.46390368	1.45668924	1.45619001	1.44424433	1.45563327
<b>5</b>	1.43690212	1.42613132	1.43484715	1.42832117	1.42603758	1.43960338
<b>6</b>	1.46273964	1.43743515	1.45170057	1.46762343	1.45434324	1.45124423
<b>7</b>	1.42470911	1.39730084	1.44111201	1.43349965	1.43728123	1.42682262
<b>8</b>	1.43744951	1.37287469	1.43293109	1.42853434	1.43239236	1.44509038
<b>9</b>	1.43742868	1.38746329	1.43172279	1.43320334	1.37180314	1.43957684
<b>10</b>	1.45421235	1.35761044	1.40878593	1.44656122	1.37687194	1.45209287
<b>11</b>	1.44954954	1.30385408	1.3835496	1.40909122	1.35327487	1.42355645
<b>12</b>	1.44788692	1.34325397	1.39666926	1.41939168	1.41252676	1.44258527
<b>13</b>	1.44385788	1.30836331	1.39734722	1.41461686	1.368195	1.44539148
<b>14</b>	1.45574734	1.32303427	1.41557658	1.44756313	1.33746616	1.43655688
<b>15</b>	1.44354081	1.34902079	1.42217434	1.4483704	1.33381525	1.44863514
<b>16</b>	1.45531718	1.33077112	1.43809896	1.44907589	1.38082872	1.45531481

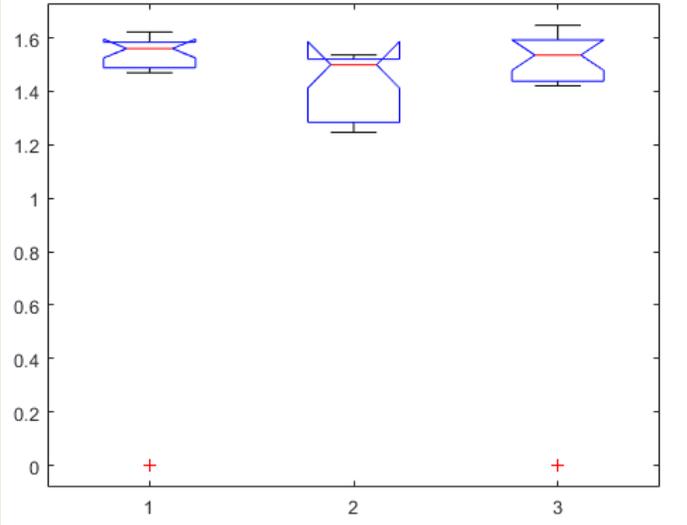
Tabla 4.3 Valores de FDK de las 6 pruebas en el sujeto 3 para el movimiento Little.

<b>Nodo</b>	<b>Prueba 1</b>	<b>Prueba 2</b>	<b>Prueba 3</b>	<b>Prueba 4</b>	<b>Prueba 5</b>	<b>Prueba 6</b>
<b>1</b>	1.43824932	1.45211499	1.45316567	1.45439799	1.43991403	1.4543154
<b>2</b>	1.44559895	1.45446631	1.44110984	1.44543369	1.42854659	1.44938143
<b>3</b>	1.43724874	1.41277429	1.43405258	1.41830664	1.39809134	1.43603814
<b>4</b>	1.45215784	1.44676907	1.4365622	1.46427768	1.4367086	1.45901058
<b>5</b>	1.42939667	1.41841628	1.41202158	1.44436307	1.37264638	1.41864797
<b>6</b>	1.44380729	1.43423802	1.44565858	1.46219909	1.36234639	1.46159071
<b>7</b>	1.42419796	1.40137917	1.43296265	1.44808704	1.36648536	1.43064177
<b>8</b>	1.40631132	1.42543076	1.4153103	1.42099366	1.3750605	1.43554295
<b>9</b>	1.43008852	1.40203929	1.42966689	1.45016857	1.31467855	1.42792288
<b>10</b>	1.43220584	1.41166069	1.43502147	1.43540611	1.31399133	1.41224306
<b>11</b>	1.39181833	1.35778742	1.42052172	1.41523778	1.29162212	1.39710261
<b>12</b>	1.39307797	1.37430582	1.43506107	1.42316484	1.34830824	1.40155496
<b>13</b>	1.41434487	1.37653726	1.44265621	1.41431037	1.29818237	1.39799973
<b>14</b>	1.4272179	1.38737721	1.46210491	1.42941938	1.2151665	1.42135933
<b>15</b>	1.44777205	1.42752308	1.45114351	1.44789151	1.27060582	1.42947977
<b>16</b>	1.46258174	1.43427221	1.44583218	1.44668613	1.30138515	1.46204848

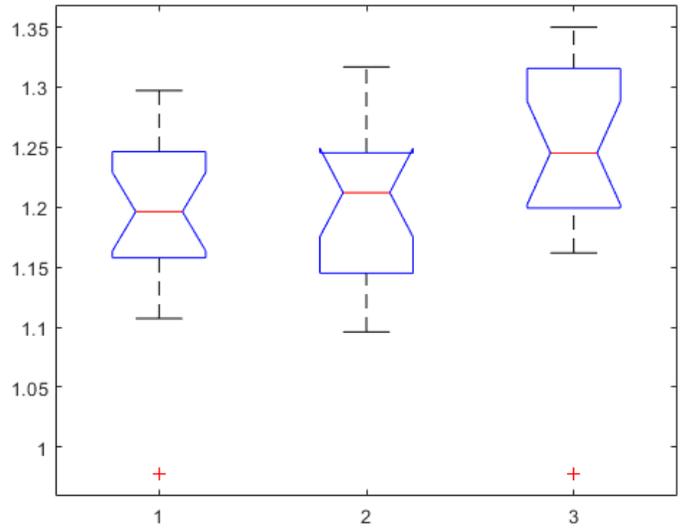
#### 4. Análisis Estadístico.

Posteriormente, se compararon los vectores obtenidos de los movimientos, se seleccionan la FD y los parámetros con más distinción en este caso Katz y los parámetros de Hjorth Actividad y Movilidad (Katz, M. J. 1988 ;Hjorth, B. 1970), así como de sus valores P respectivos de los vectores de 3 sujetos, en estos, se puede observar algunos métodos que destacan sobre otros; tal es el caso de Katz 4, Complejidad 3, Movilidad 3 y Movilidad 4, con valores P de entre 0.01 y 0.04, además de buenas distribuciones y en la media de los diagramas.

Tabla 4.4. Comparativa de ANOVA para los diferentes extractores de características con vectores de las 3 clases de movimiento.

Característica	Diagrama de cajas y bigotes	Nodo	Valor P
Movilidad		1	0.0597

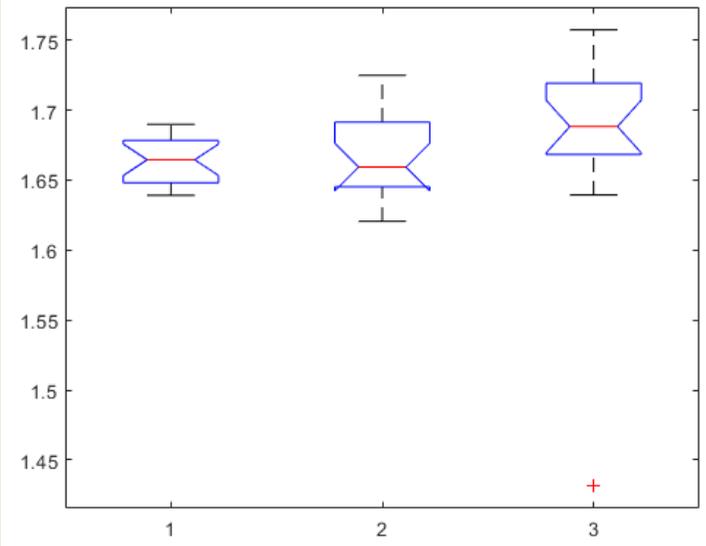
**Movilidad**



3

0.0423

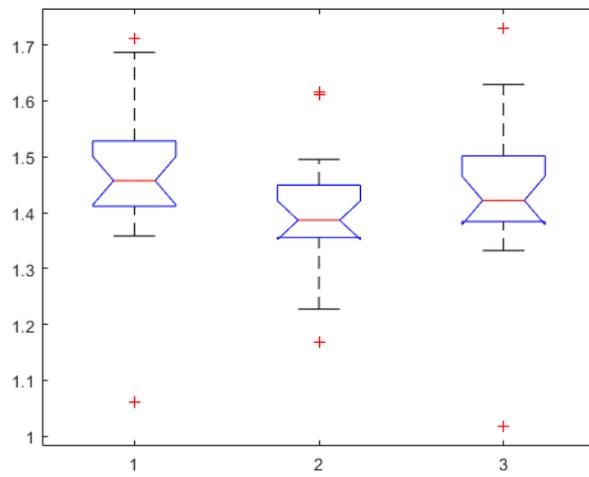
**Movilidad**



4

0.0315

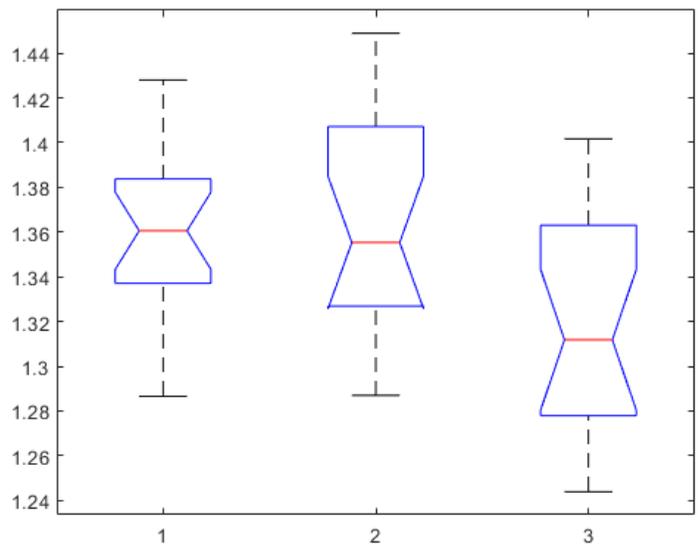
**Movilidad**



13

0.0850

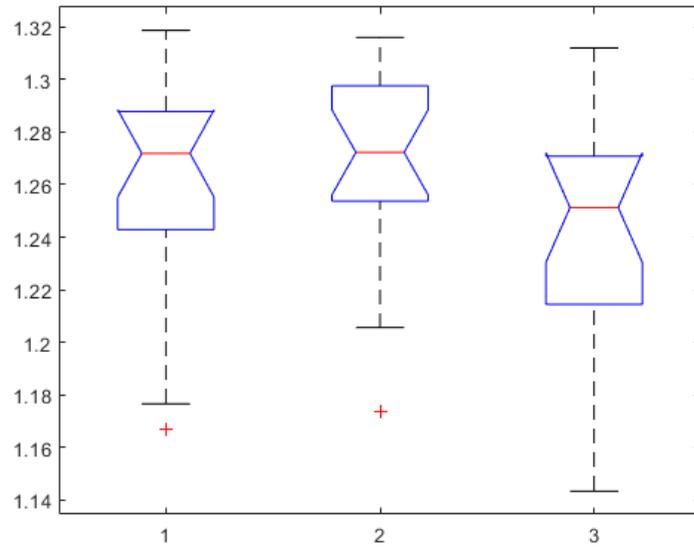
**Complejidad**



3

0.0117

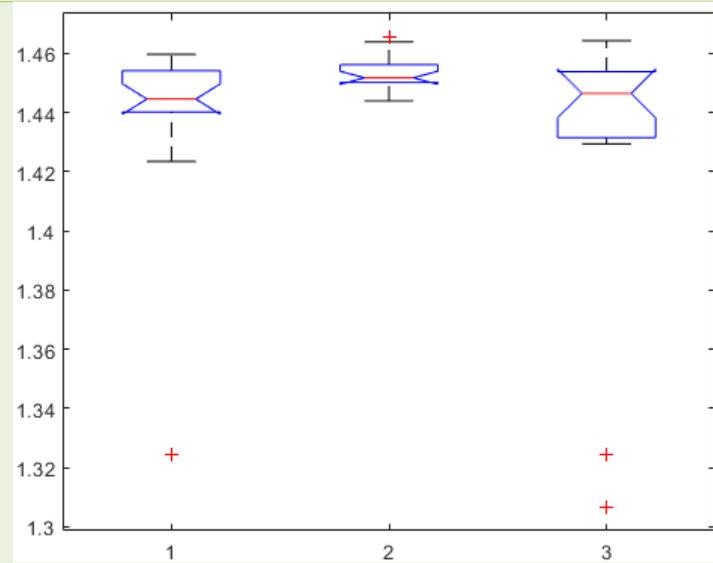
**Complejidad**



9

0.0586

**FDK**



4

0.0369

<b>FDK</b>		7	0.0090
<b>FDK</b>		8	0.0034

Dado los resultados anteriores, así como el valor P de varios diagramas de cajas y bigotes, se opta por tomar 4 métodos como entradas en la siguiente etapa, los cuales fueron: KFD4, KFD7, Movilidad 3 y Movilidad 4. Esto también con el objetivo de aprovechar de mejor manera la información disponible en los vectores, ya que en total se obtienen 54 datos.

## 5. Clasificación

Antes de realizar la clasificación, los datos deben estar preparados para que los datos estén disponibles para el entrenamiento, validación y prueba de la red. Por lo tanto, se generaron dos conjuntos de datos para entrenamiento y validación. Teniendo los 4 métodos seleccionados, cada uno con un vector de 54 datos de cada método, teniendo en cuenta que cada vector se construye a partir de las 6 muestras de los tres movimientos de tres pacientes. Se divide un primer vector con una matriz de 4 renglones por 48 columnas; este conjunto como entrada de la RN para la etapa de entrenamiento, nótese que el vector está siendo reducido 4 espacios por cada movimiento.

De esta manera, la RN se identifica que los primeros 14 valores de las entradas corresponden a Index, los segundos 14 valores a Middle y los últimos 14 valores a Little. El segundo conjunto se presenta con una matriz de 3x12 en donde, el primer renglón contiene en los primeros 14 espacios, valores de uno y el resto de ceros, en el segundo renglón, los primeros 14 espacios son ceros y el resto son unos; este conjunto representa a los objetivos a los cuales debe de llegar la RN.

Con los datos listos para usar, se diseñaron diferentes redes con diferentes números de neuronas en las capas ocultas, pero finalmente se identificó una red con 12 neuronas en la capa oculta. Se determinó que para entrenar todas estas redes se utilizó un algoritmo de gradiente conjugado, ya que es el más eficiente entre el uso de recursos computacionales y la precisión del clasificador. Esta red mostró una exactitud del 71.4% en la etapa de entrenamiento, como se muestra en la matriz de confusión en la Tabla 4.2. Consecuentemente, la red mostró tener 83.3% de exactitud en la etapa de validación, como se puede observar en la matriz de confusión en la Tabla 4.3.

Tabla 4.2 Matriz de confusión de entrenamiento

**Matriz de confusión de entrenamiento**

<b>Clase de salida</b>	1	5	0	0	100%
		11.9%	0.0%	0.0%	0.0%
	2	7	14	100%	58.3%
		16.7%	33.3%	0.0%	0.0%
3	2	0	11	84.6%	
	4.8%	0.0%	26.2%	15.4%	
	35.7%	100%	78.6%	71.4%	
	64.3%	0.0%	21.4%	28.6%	
		1	2	3	
		<b>Clase objetivo</b>			

Tabla 4.3 Matriz de confusión de validación

**Matriz de validación**

<b>Clase de salida</b>	1	1	0%	0%	100%
		16.7%	0.0%	0.0%	0.0%
	2	1	2	0%	66.7%
		16.7%	33.3%	0.0%	0.0%
3	0%	0%	2	100%	
	0.0%	0.0%	33.3%	0.0%	
	50.0%	100%	100%	83.3%	
	50.0%	0.0%	0.0%	16.7%	
		1	2	3	

## Clase objetivo

Posteriormente y como último paso de la metodología, se probó la RN con los datos nuevos mencionados previamente (la información de los 4 valores restantes de cada vector); esta demostró tener un 75.5% de exactitud, como se puede ver en la Tabla 4.4.

Tabla 4.3 Matriz de confusión de prueba

**Matriz de confusión de prueba**

<b>Clase de salida</b>	1	<b>4</b> <b>33.3%</b>	<b>0%</b> <b>0.0%</b>	<b>1</b> <b>8.3%</b>	<b>100%</b> <b>0.0%</b>
	2	<b>0</b> <b>0.0%</b>	<b>4</b> <b>33.3%</b>	<b>2</b> <b>16.7%</b>	<b>66.7%</b> <b>0.0%</b>
	3	<b>0</b> <b>0.0%</b>	<b>0</b> <b>0.0%</b>	<b>1</b> <b>8.3%</b>	<b>100%</b> <b>0.0%</b>
		<b>100%</b> <b>0.0%</b>	<b>100%</b> <b>0.0%</b>	<b>25.0%</b> <b>75.0%</b>	<b>75.0%</b> <b>25.0%</b>
	1	2	3		
		<b>Clase objetivo</b>			

## 4.2. Discusión de resultados

Los resultados obtenidos previamente utilizando el método propuesto, representan una precisión del 71.4% para distinguir los movimientos Índice (I), Medio (M) y Meñique (L). Esto se logra utilizando técnicas de baja carga computacional como WPT, parámetros de Hjorth y técnicas de FD (Tuncer, et al. 2022; Amezquita-Garcia, et al., 2021). En el estudio anterior, se clasificaron 15 diferentes señales EMG (utilizando diferentes métodos), ya que las técnicas utilizadas requieren altos recursos computacionales. Sin embargo, WPT, parámetros de Hjorth, FD y RN multicapa han demostrado ser métodos no lineales eficientes para analizar señales de EMG.

La siguiente tabla 4.6 muestra algunos de los resultados obtenidos por otros investigadores en los últimos años para la detección de señales EMG.

Autor(es)	Movimientos	Metodología	Resultados
(Shair, et al., 2020).	Pulgar (T), índice (I), medio (M), Anillo (R), Meñique (L). Movimientos combinados: Mano cerrada (HC), Pulgar-índice (T-I), Pulgar-Meñique (T-L), Pulgar-Medio (T-M) y Pulgar-Anular (T-R).	<ol style="list-style-type: none"> <li>1. Preparación de la señal, filtro de paso de banda con un rango entre 20 y 450 Hz.</li> <li>2. El desplazamiento de la señal utilizando los medios de la señal de referencia y la autosegmentación según lo propuesto por (Shair, E. et al. 2016).</li> <li>3. Extracción de características por distribución de tiempo-frecuencia (TFD).</li> <li>4. Clasificación a través redes neuronales artificiales (ANN), clasificador bayesiano (BC), lógica difusa (FL), perceptrón multicapa (MLP), máquinas de vectores de soporte (SVM), análisis de discriminación lineal (LDA), modelos ocultos de Markov (HMM) y K-Neighbour más cercano (KNN).</li> </ol>	100% de exactitud de clasificación para 10 movimientos de prueba.
(Hayashi, H et al., 2021).	M1: Apertura de mano; M2: Agarre manual; M3: Extensión de muñeca; M4: Flexión de muñeca; M5: Pronación; M6: Supinación.	<ol style="list-style-type: none"> <li>1. Preparación de la señal se registra utilizando trece pares de electrodos a 1 kHz con un filtro de notch de 60 Hz y un filtro de pasa de banda de 0,1 a 200 Hz.</li> <li>2. Segmentados de las señales para luego ser convertidos en vectores de características. Los vectores se clasifican en categorías predefinidas.</li> <li>3. Extracción de características por el sistema de traducción de Jonson (Johnson, N. L. 1949).</li> <li>4. Clasificación comparativa a través de SVM , LLGMN, MLP, Regresión Lógica Lineal (LLR), k-NN, Random forest</li> </ol>	60.72% de exactitud de clasificación para 6 movimientos de prueba.
(Tuncer, et al. 2022).	Pulgar (T_T), índice (I_I), medio (M_M), anular (R_R), meñique (L_L), las combinaciones TI, TM, TR, TL, IM, MR, RL, IMR, MRL y la mano cerrada (HC).	<ol style="list-style-type: none"> <li>1. Preparación de la señal, filtro de paso de banda con un rango entre 20 y 450 Hz</li> <li>2. Se procesa la señal por medio de 1D-DWT se ha utilizado para crear subbandas y estas subbandas se han utilizado para generar funciones de alto nivel.</li> <li>3. Extracción de características a través de un micropatrón textural denominado multi-patrón binario centrado (MCBP).</li> <li>4. Clasificación comparativa de Máquinas de Vectores de Soporte (SVM) y red neuronal multicapa (NN).</li> </ol>	99,70% de exactitud de clasificación para 15 movimientos de prueba.
(Amezquita-García,	Pulgar (T_T), Índice (I_I), Medio (M_M),	1. Importación de la base de datos al entorno MATLAB. Los valores atípicos se eliminan	92,89% de exactitud de

et al., 2021)	Anular (R_R), Meñique (L_L), las combinaciones  TI, TM, TR, TL, IM, MR, RL, IMR, MRL y la mano cerrada (HC).	mediante el método de eliminación de valores atípicos con una distribución chi-cuadrada.  2. Los datos están en ventanas, agrupando 160 muestras de datos EMG. Se buscan sugerencias de características en la investigación de EMG, las características se extraen para cada ventana. A partir de estas agrupaciones se crea una matriz para todas las materias.  3. Con la nueva base de datos, el algoritmo de selección secuencial directa de características (SFS) es mejorado. Los datos se normalizan para dar el mismo peso a las características evaluadas del espacio de las características pasamos a un espacio de matrices dispersas.  4. El nuevo clasificador se crea a partir del algoritmo discriminante cuadrático con un Acercamiento Bayesiano.	clasificación para 15 movimientos de prueba.
(Iqbal, N. V., & Subramaniam, K. 2018).	Flexión de Pulgar, Flexión de Índice, Combinación Pulgar Índice, Empuñadura trípode de Escritura, Agarre de Gancho y Agarre Esférico.	1. Se adquirió una frecuencia de muestreo de 2000 Hz utilizando una adquisición mediante un sistema de EMG multicanal hecha a medida.  2. Procesamiento de las señales a través de Wavelet Packet Entropy.  3. Extracción de características por medio de Entropía de energía espectral (SEN) y Entropía de permutación (PEN).  4. La clasificación se hace usando lineal análisis discriminante (LDA), Red neuronal probabilística (PNN) y máquina de vectores de soporte (SVM).	92% de exactitud de clasificación para 6 movimientos de prueba.

Se pueden hacer varios puntos al comparar los datos de investigación en la Tabla 4.6 con la metodología propuesta en este proyecto.

- Con el método propuesto en este proyecto, la precisión alcanzada es del 71,72%. Mejor precisión que otros estudios sobre el tema en cuestión (Hayashi, H et al., 2021).
- No fue necesario una técnica de filtrado previo adicional aminorando la carga de computación (Iqbal, N. V., & Subramaniam, K. 2018; Amezcuita-Garcia, et al., 2021).
- En esta investigación, se utilizan técnicas de FD y parámetros de Hjorth para la extracción de características junto con un análisis tiempo-frecuencia (WPT) en

contraste con las técnicas más complejas utilizadas en otras investigaciones (Tuncer, et al. 2022; Iqbal, N. V., & Subramaniam, K. 2018; Shair, et al., 2020).

- Se emplearon las 6 muestras de 3 pacientes para la extracción de características, haciendo más detallado el análisis comparado con algunas investigaciones presentadas en señales de EMG, asimismo se utilizaron 4 métodos como entradas para la Red Neuronal Multicapa teniendo más información disponible para su clasificación (Hayashi, H et al., 2021; Tuncer, et al. 2022; Iqbal, N. V., & Subramaniam, K. 2018; Shair, et al., 2020).

## CAPÍTULO 5

### CONCLUSIÓN Y PROSPECTIVAS

#### **5.1. Conclusiones**

Las señales de EMG en general representan una amplia área de análisis tanto para el desarrollo de prótesis como para su estudio clínico. En la actualidad se cuentan con diversos dispositivos y procesos que se pueden mejorar utilizando las señales, consecuentemente para este tipo de métodos así como los datos puedan incluirse dentro de equipos médicos u otras pruebas clínicas; por esta razón, es importante profundizar en estos temas y mejorar los análisis existentes.

En el presente proyecto, se hace uso de una base de datos de la Universidad de Tecnología en Sydney, Australia (Khushaba et al., 2012); en este caso, las señales de EMG se recolectaron de 8 sujetos de prueba. La base de datos de tres flexiones de la mano (índice, medio y meñique) ha sido procesada con WPT, lo que muestra tiempos de cómputo significativamente mejorados (Rahman et al.2020); posteriormente, fue procesada la información con distintas técnicas de DF, análisis de Hjorth y medidas de textura en las descomposiciones de la WPT, a su vez se hizo un estudio preliminar mediante un método gráfico donde se descartaron aquellos algoritmos que no mostraban una distinción entre los valores del mismo nodo de descomposición de este análisis, se eligieron los métodos de Katz, Complejidad y Movilidad. Luego se analizan usando ANOVA para distinguir entre

los nodos con estas características que presenten un mayor diferencial entre sí, los cuales fueron: Katz 4, Complejidad 3, Movilidad 3 y Movilidad 4; finalmente, se marcó con una RN multicapa de 12 neuronas en la capa oculta que mostró una precisión del 71,4% en la detección de las mencionadas flexiones de la mano en señales de EMG.

Estos resultados son aceptables en comparación con ensayos anteriores, donde se utilizó una mayor carga computacional debido a las técnicas de análisis, extracción de características o clasificación; Aún con una exactitud menor de algunos ensayos anteriores y una base de datos de menor magnitud se obtuvieron resultados deseados hasta el momento. Por esta razón, se cree que la metodología presentada anteriormente en este trabajo, así como su implementación, se completó con éxito.

## **5.2. Prospectivas**

A pesar de los buenos resultados presentados anteriormente, hay varias observaciones que podrían mejorar el método o mejorar partes del proceso. Algunos de estos puntos se mencionan a continuación:

- Se propone utilizar variaciones de WPT en señales de EMG o Electrocardiograma (ECG) con el fin de obtener descomposiciones con la menor cantidad de ruido sin comprometer la baja carga computacional
- Se pretende ampliar el dominio del tiempo en el tamaño de las muestras en futuros proyectos para aumentar el tamaño de ventana en el análisis tiempo-frecuencia, para detectar cambios más sutiles en la señal.
- Se propone una etapa intermedia más extensa para la selección de algoritmos para el procesamiento de la señal, ya que en este tipo de datos la frecuencia puede variar significativamente entre muestras del mismo paciente.
- Se sugiere hacer una comparativa entre distintas formas de clasificación de señales a través de inteligencia artificial.

De igual manera, se proponen algunas formas de continuar con esta investigación:

- Se propone un sistema de clasificación de actuadores conjuntos en la RN para alcanzar una mayor eficiencia en la detección de las señales EMG.

- Se propone crear un sistema de adquisición de señales de EMG para comprobar el desempeño de la metodología con datos propios adquiridos y con datos en tiempo real.
- Una vez analizada de forma más exhaustiva esta metodología, se propone incluir de todos los movimientos individuales y las combinaciones de las flexiones de los dedos de la mano.

## REFERENCIAS BIBLIOGRÁFICAS

Adrian ED, Bronk DW. The discharge of impulses in motor nerve fibers II. The frequency of discharge in reflex and voluntary contraction. *J Physiol.* 1929;67:119-151.

Barişçi, N. (2008). The adaptive ARMA analysis of EMG signals. *Journal of medical systems*, 32(1), 43-50.

Chen, M., & Liu, H. (2020). Robot arm control method using forearm EMG signals. In *MATEC Web of Conferences* (Vol. 309, p. 04007). EDP Sciences.

Day S. Important factors in surface EMG measurement. Calgary: Bortec Biomedical Ltd Publishers; 2002. pp. 1–7.

Harada, H., Kashiwagi, H., Nishimura, H., Ohbuchi, Y., & Yamaguchi, T. (2008, October). Electromyogram signal processing by using M-transform. In *2008 International Conference on Control, Automation and Systems* (pp. 2446-2449). IEEE.

Higuchi, T. (1988). Approach to an irregular time series on the basis of the fractal theory. *Physica D*, 31, 277-283.

Hijar, M. (2015). Epidemiología de las . “*Los amputados. Un reto para el Estado*” (págs. 2-3). México: Academia Nacional de Medicina.

Ibarra-Manzano, M. A., Almanza-Ojeda, D. L., & Lopez-Hernandez, J. M. (2010, September). Design and optimization of real-time texture analysis using sum and difference histograms implemented on an fpga. In *2010 IEEE Electronics, Robotics and Automotive Mechanics Conference* (pp. 325-330). IEEE.

Katz, M. J. (1988). Fractals and the analysis of waveforms. *Comput. Biol. Med.*, 18, 145-156.

- Khushaba, R. N., Kodagoda, S., Takruri, M., & Dissanayake, G. (2012). Toward improved control of prosthetic fingers using surface electromyogram (EMG) signals. *Expert Systems with Applications*, 39(12), 10731-10738.
- Marcolin, G., & Petrone, N. (2008). Acquisition and Analysis of EMG Data During Special Slalom for Comparative Equipment Evaluation (P228). *The Engineering of Sport 7*, 411-418.
- Lavry, D. (2004). Sampling Theory For Digital Audio. Lavry Engineering. Inc.: Kingston, WA, USA.
- Pancholi, S., & Joshi, A. M. (2018). Portable EMG data acquisition module for upper limb prosthesis application. *IEEE Sensors Journal*, 18(8), 3436-3443.
- Pérez, A. (2018). *Metodología basada en la transformada wavelet y fractales para la detección anticipada de eventos epilépticos* (Tesis de pregrado). Universidad Autónoma de Querétaro.
- Unser, M. (1986). Sum and difference histograms for texture classification. *IEEE transactions on pattern analysis and machine intelligence*, (1), 118-125.
- Vázquez, E. (2015). “Los amputados. Un reto para el Estado”. *Introducción* (págs. 1-2). Mexico: Academia Nacional de Medicina.
- Wang, B. (2005). Detection of structural damage using fractal dimension technique. *Vib. Shock*, 24, 87-88.
- Yang, Y. H., Ruan, S. J., Chen, P. C., Liu, Y. T., & Hsueh, Y. H. (2020). A low-cost wireless multichannel surface EMG acquisition system. *IEEE Consumer Electronics Magazine*, 9(5), 14-19.
- Zurmühle, P. (2017). Erfassung von Bewegungsdaten der Hand mit EMG für Anwendungen in der Ergotherapie.
- Alva Coras, C. A. (2012). Procesamiento de señales de electromiografía superficial para la detección de movimiento de dos dedos de la mano.
- Jali, M. H., Ibrahim, I. M., Sulaima, M. F., Bukhari, W. M., Izzuddin, T. A., & Nasir, M. N. I. (2015, May). Features extraction of EMG signal using time domain analysis for arm rehabilitation device. In *AIP Conference Proceedings* (Vol. 1660, No. 1, p. 070041). AIP Publishing LLC.
- Too, J., Abdullah, A. R., Zawawi, T. T., Saad, N. M., & Musa, H. (2017). Classification of emg signal based on time domain and frequency domain features. *International Journal of Human and Technology Interaction (IJHaTI)*, 1(1), 25-30.

Fattah, S. A., Iqbal, M. A., Jumana, M. A., & Doulah, A. S. U. (2012). Identifying the motor neuron disease in EMG signal using time and frequency domain features with comparison. *Signal & Image Processing*, 3(2), 99.

Hong, D., Wang, J., & Gardner, R. (2005). *Real Analysis with an Introduction to Wavelets*.

Scheme, E., Founger, A., Stavdahl, O., Chan, A. D. C., & Englehart, K. (2010). Examining the adverse effect of limb position on pattern recognition based myoelectric control. In *Proceedings of the 32nd annual international conference of the IEEE EMBS*

Guresen, E., & Kayakutlu, G. (2011). Definition of artificial neural networks with comparison to other networks. *Procedia Computer Science*, 3, 426-433.

Wang, S. C. (2003). Artificial neural network. In *Interdisciplinary computing in java programming* (pp. 81-100). Springer, Boston, MA.

Irvine, N., Nugent, C., Zhang, S., Wang, H., & Ng, W. W. (2019). Neural network ensembles for sensor-based human activity recognition within smart environments. *Sensors*, 20(1), 216.

Sohal, H., & Jain, S. (2018). Comparative analysis of heart rate variability parameters for arrhythmia and atrial fibrillation using ANOVA. *Biomedical and Pharmacology Journal*, 11(4), 1841-1849.

Rahman, M., Khanam, F., Ahmad, M., & Uddin, M. S. (2020). Multiclass EEG signal classification utilizing Rényi min-entropy-based feature selection from wavelet packet transformation. *Brain informatics*, 7(1), 1-11.

Nikookar, H. (2013). *Wavelet radio: adaptive and reconfigurable wireless systems based on wavelets*. Cambridge University Press.

Nikookar, H. (2013). Theory of wavelets. *Wavelet Radio*, 11–34.  
<https://doi.org/10.1017/cbo9781139084697.003>

Li, T., & Zhou, M. (2016). ECG classification using wavelet packet entropy and random forests. *Entropy*, 18(8), 285.

Zhang, D. (2019). Wavelet transform. In *Fundamentals of Image Data Mining* (pp. 35-44). Springer, Cham.

Rafiee, J., Schoen, M. P., Prause, N., Urfer, A., & Rafiee, M. A. (2009, February). A comparison of forearm EMG and psychophysical EEG signals using statistical signal processing. In *2009 2nd International Conference on Computer, Control and Communication* (pp. 1-5). IEEE.

Shair, E. F., Abdullah, A. R., Zawawi, T. T., Ahmad, S. A., & Saleh, S. M. (2016). Auto-segmentation analysis of EMG signal for lifting muscle contraction activities. *Journal of Telecommunication, Electronic and Computer Engineering (JTEC)*, 8(7), 17-22.

Hayashi, H., Shibasaki, T., & Tsuji, T. (2021). A Neural Network Based on the Johnson S U Translation System and Related Application to Electromyogram Classification. *IEEE Access*, 9, 154304-154317.

Shair, E. F., Jamaluddin, N. A., & Abdullah, A. R. (2020). Finger Movement Discrimination of EMG Signals Towards Improved Prosthetic Control Using TFD. *Int. J. Adv. Comput. Sci. Appl.(IJACSA)*, 11, 244-251.

Johnson, N. L. (1949). Systems of frequency curves generated by methods of translation. *Biometrika*, 36(1/2), 149-176.

Tuncer, T., Dogan, S., & Subasi, A. (2022). Novel finger movement classification method based on multi-centered binary pattern using surface electromyogram signals. *Biomedical Signal Processing and Control*, 71, 103153.

Amezquita-Garcia, J. A., Bravo-Zanoguera, M. E., Avitia, R. L., Reyna, M. A., & Cuevas-González, D. (2021). OpenSim Visualization of the Classification of Finger Movements Based on Electromyography Signal as the Single-Input Variable during Predefined Movements. *Engineering Proceedings*, 10(1), 7.

Iqbal, N. V., & Subramaniam, K. (2018). Wavelet Packet Entropy Based Control of Myoelectric Prosthesis. *Biomedical and Pharmacology Journal*, 11(1), 375-380.

Piña-Vega, R., Valtierra-Rodriguez, M., Perez-Ramirez, C. A., & Amezquita-Sanchez, J. P. (2021). Early prediction of sudden cardiac death using fractal dimension and ecg signals. *Fractals*, 29(03), 2150077.

Hjorth, B. (1970). EEG analysis based on time domain properties. *Electroencephalography and clinical neurophysiology*, 29(3), 306-310.

Webster, J. G. (2006). *Encyclopedia of Medical Devices and Instrumentation Second Edition Vol. 4*.

Prutchi, D., & Norris, M. (2005). Bandpass selection for biopotential amplifiers. *Design and Development of Medical Electronic Instrumentation: A Practical Perspective of the Design, Construction, and Test of Medical Devices*, 2-6.

Alva Coras, C. A. (2012). Procesamiento de señales de electromiografía superficial para la detección de movimiento de dos dedos de la mano.

Healthwise. (2021). [Esquema ilustrado de Inervación de las manos]. Sensibilidad de la piel de las manos.

[https://content.healthwise.net/resources/13.2/esus/media/medical/hw/s\\_h9991344\\_001.jpg](https://content.healthwise.net/resources/13.2/esus/media/medical/hw/s_h9991344_001.jpg)

Arévalo González, D. (2021). Diseño e implementación de redes neuronales de aprendizaje profundo para clasificación y análisis de movimientos corporales capturados mediante dispositivos vestibles.

Perdomo, M. A. F., Gómez, V. G., Cañón, Á. D. O., & Olaya, A. F. R. (2021). Classification of the Angular Position During Wrist Flexion-Extension Based on EMG Signals. *Ingeniería y universidad*, 25, 4.

Du, K. L., & Swamy, M. N. (2006). *Neural networks in a softcomputing framework* (Vol. 501). London: Springer.

Harada, H., Kashiwagi, H., Nishimura, H., Ohbuchi, Y., & Yamaguchi, T. (2008, October). Electromyogram signal processing by using M-transform. In *2008 International Conference on Control, Automation and Systems* (pp. 2446-2449). IEEE.

Namazi, H. (2019). Decoding of hand gestures by fractal analysis of electromyography (EMG) signal. *Fractals*, 27(03), 1950022.

Xiao, H., Zhi-zhong, W., & Xiao-mei, R. (2005). Classification of surface EMG signal with fractal dimension. *Journal of Zhejiang University Science B*, 6(8), 844-848.

Benítez Aldás, M. R. (2018). *Estudio y análisis de métodos para la extracción de características y clasificación de emociones basados en EEG* (Master's thesis).

Unser, M. (1986). Sum and difference histograms for texture classification. *IEEE transactions on pattern analysis and machine intelligence*, (1), 118-125.