



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO**  
**PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA**  
**INGENIERÍA ELÉCTRICA - PROCESAMIENTO DIGITAL DE SEÑALES**

**ANÁLISIS DE SEÑALES EMG DE SUPERFICIE BASADO EN LA TRANSFORMADA  
HILBERT - HUANG PARA EL RECONOCIMIENTO DE GESTOS DE LA MANO**

**TESIS**

**QUE PARA OPTAR POR EL GRADO DE:  
MAESTRO EN INGENIERÍA**

**PRESENTA:  
GUSTAVO PACHECO SANTIAGO**

**TUTOR PRINCIPAL:  
DR. MIGUEL ÁNGEL PADILLA CASTAÑEDA  
INSTITUTO DE CIENCIAS APLICADAS Y TECNOLOGÍA (ICAT)**

**CIUDAD UNIVERSITARIA, CD.MX MARZO 2022**



Universidad Nacional  
Autónoma de México



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

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

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

## **JURADO ASIGNADO**

Presidente: Dr. Savage Carmona Jesús

Secretario: Dr. Pérez Alcázar Pablo Roberto

1<sup>er</sup>. Vocal: Dr. Padilla Castañeda Miguel Ángel

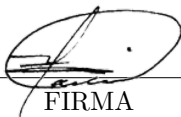
2<sup>do</sup>. Vocal: Dra. Medina Gómez Lucía

3<sup>er</sup>. Vocal: Dr. Gutiérrez Herrera Enoch

Ciudad Universitaria, Instituto de Ciencias Aplicadas y Tecnología (ICAT). Programa de Maestría y Doctorado en Ingeniería Eléctrica, UNAM.

### **TUTOR DE TESIS:**

Dr. Padilla Castañeda Miguel Ángel

  
FIRMA

# Agradecimientos

*Agradezco a la Universidad Nacional Autónoma de México por brindarme la oportunidad de continuar con mis estudios de posgrado.*

*A mis padres que son los detonantes de mi felicidad, de mi fuerza y de mi dedicación; su cariño y templanza fueron la clave para lograr este objetivo que ahora veo reflejado, su trabajo arduo de todos los días hizo realidad una de mis metas, es por ello que valoré cada día de estudio.*

*Al Dr. Miguel Ángel Padilla Castañeda por confiar en mí, por darme la oportunidad de participar en sus investigaciones y por toda su orientación y apoyo a lo largo de este tiempo. Gracias por la confianza depositada en mi persona ya que me permitió que continuara con mis estudios en un momento en donde se me hacía una meta lejana de realizar. A mis profesores, personas que contribuyeron a mi formación profesional y personal. Gracias por el apoyo brindado.*

*A mis sinodales por su tiempo y dedicación en la revisión de este trabajo.*

*Agradezco la financiación recibida por parte de Consejo Nacional de Ciencia y Tecnología - CONACYT y a UNAM DGAPA-PAPIIT TA10920 por el apoyo para la realización de este proyecto y a SECTEI 219/2019 por la beca de maestría recibida.*

# Dedicatoria

*A mis padres por todo su apoyo, comprensión y cariño.  
Gracias a su esfuerzo, dedicación y trabajo todo esto ha sido posible.  
A toda mi familia que siempre han depositado su confianza en mí.*

# Resumen

El siguiente trabajo de investigación tiene por objetivo el reconocimiento de movimientos de la mano para tener aplicaciones enfocadas principalmente a prótesis de mano. En la actualidad el uso de la electromiografía permite un enfoque en el que diversas disciplinas lo toman de referencia para el desarrollo de dispositivos y equipos de rehabilitación, los cuales serán controlados mediante señales electromiográficas. Con el uso y aplicación de este tipo de señales en dispositivos protésicos permitiría un control natural y lo más cercano a la realidad, con lo cual personas que han sufrido la pérdida de esta parte de la extremidad superior (mano) puedan recuperar cierta movilidad permitiéndoles nuevamente su integración a la sociedad y al ámbito laboral. Para realizar y evaluar el reconocimiento de gestos se seleccionó una base de datos electromiográficos obtenidos al realizar diversas tareas con objetos de uso común, la base de datos seleccionada fue NINAPRO (Non Invasive Adaptive Prosthetics) la cual se utiliza en investigaciones sobre manos robóticas y protésicas controladas con inteligencia artificial. De esta manera se pudo evaluar, comparar y analizar si existen diferencias en la señal electromiográfica al momento de realizar cada una de las diversas tareas con objetos distintos y por lo tanto poder hacer un reconocimiento y clasificación de movimientos.

Muchas investigaciones que tratan en reconocer patrones contenidos en las señales electromiográficas usan diversos métodos de descomposición, lo que permite obtener información multiresolución describiendo más a detalle y a profundidad la señal. Así para el reconocimiento de movimientos de la mano se realiza la implementación de tres métodos de descomposición de señales los cuales son: transformada Wavelet discreta (DWT: *Discrete Wavelet Transform*), descomposición de modos empíricos por conjuntos (EEMD: *Ensemble Empirical Mode Decomposition*) y descomposición de modo variacional (VMD: *Variational Mode Decomposition*) consiguiendo tener una comparación entre los alcances que nos da cada uno de estos métodos para efectuar el correcto reconocimiento de movimientos. Al tratarse de un análisis con una señal compleja se tuvo que implementar una etapa que permitió acondicionar las señales para que estas fueran las más óptimas posibles para su posterior análisis. Tomando como entrada las señales electromiográficas de superficie estas ingresan primeramente a una etapa de preprocesamiento la cual consta de dos subetapas las cuales son: filtrado y normalización, la primera de ellas posee tres filtros para la eliminación de diversos tipos de ruido, estos filtros son: un filtro Hampel, Notch y un filtro pasa banda Butterworth, la segunda etapa es la normalización, que es crucial para comparar los niveles de actividad muscular entre distintos músculos y entre distintos sujetos. Posteriormente se hace una descomposición de la señal mediante los métodos de descomposición de señales mencionados anteriormente.

A continuación se plantea el uso de una taxonomía para poder mejorar el reconocimiento de movimientos, puesto que muchos de ellos resultan ser muy similares, esto ayuda a agrupar a los movimientos por sus características al momento de efectuar un agarre. De igual manera se plantea el ventaneo de las señales para poder analizar su implementación en aplicaciones en

tiempo real, este análisis plantea el uso de dos tamaños de ventana el primero de ellos con un tamaño de 300 ms el cual es el tamaño mínimo para que pueda ser considerado en aplicaciones en tiempo real y un tamaño de 500 ms que nos permitirá saber los efectos de variar el tamaño de ventana al momento de realizar la clasificación de los movimientos. También se planteó un análisis para ver los efectos del uso de cierto número de sensores para extraer u obtener la señal electromiográfica de superficie ya que debido al uso de un número considerable de sensores esto podría traer redundancias al sistema de clasificación.

El extraer características en los dominios del tiempo y de la frecuencia es fundamental para modelar el comportamiento de las señales, para cada método de descomposición se obtuvo un vector de características tiempo-frecuencia. Sin embargo debido a la gran cantidad de características y a la redundancia entre algunas de ellas hace que sea necesario una etapa de selección y reducción de características por medio de la cual solamente se seleccionaran las características que presenten diferencia entre las distintas clases de movimientos, esta selección se realiza utilizando la prueba no paramétrica Kruskal-Wallis, la cual nos permite probar si un grupo de datos proviene de la misma población, la reducción de características mediante el método ULDA (*Uncorrelated Linear Discriminant Analysis*) consiste en mapear los vectores de características a una dimensión menor que sea más adecuada para la clasificación. Para el reconocimiento de patrones tres técnicas de aprendizaje automático fueron utilizadas: k-vecinos más cercanos (KNN: *K-Nearest Neighbors*), máquinas de soporte vectorial (SVM: *Support Vector Machine*) y árboles de decisión (DT: *Decision Trees*) que de igual manera nos permitió hacer una comparación entre la exactitud de cada uno de estos métodos al momento de predecir y clasificar los movimientos.

# Índice general

<b>Resumen</b>	<b>v</b>
<b>Índice de tablas</b>	<b>ix</b>
<b>Índice de figuras</b>	<b>ix</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Planteamiento del problema . . . . .	1
1.2. Aplicaciones de las señales EMG a los dispositivos protésicos . . . . .	1
1.3. Hipótesis . . . . .	2
1.4. Objetivo General . . . . .	2
1.4.1. Objetivos Específicos . . . . .	2
1.5. Estructura de la tesis . . . . .	3
<b>2. Prótesis con control electromiográfico</b>	<b>4</b>
2.1. La extremidad superior . . . . .	4
2.2. Señales electromiográficas . . . . .	5
2.2.1. La unidad motora . . . . .	6
2.2.2. Potencial de acción de la unidad motora (PAUM) . . . . .	6
2.3. Análisis sEMG aplicado al reconocimiento de gestos . . . . .	7
2.4. Taxonomía de la mano . . . . .	9
2.5. La mano como elemento de percepción háptica . . . . .	11
<b>3. Metodología</b>	<b>12</b>
3.1. Base de datos EMG . . . . .	12
3.1.1. Adquisición de las señales sEMG . . . . .	13
3.2. Sistema de clasificación de gestos mediante señales EMG . . . . .	15
3.3. Preprocesamiento de la señales . . . . .	17
3.3.1. Eliminación de ruido: Etapa de filtrado . . . . .	17
3.3.1.1. Detección de datos atípicos: Filtro Hampel . . . . .	18
3.3.1.2. Eliminación del ruido y límites del ancho de banda: Filtro Notch y Pasa banda . . . . .	18
3.3.2. Normalización . . . . .	20
3.4. Análisis para el reconocimiento de gestos . . . . .	20
3.4.1. Análisis por Transformada Wavelet Discreta . . . . .	21
3.4.2. Análisis por Descomposición de Modos Empíricos por Conjuntos . . . . .	23
3.4.2.1. Descomposición de modos empíricos . . . . .	23
3.4.2.2. Descomposición de Modos Empíricos por Conjuntos . . . . .	25
3.4.3. Análisis por Descomposición de Modo Variacional . . . . .	27
3.5. Ventaneo de las señales sEMG . . . . .	30



3.6.	Extracción de características . . . . .	31
3.6.1.	Características en el dominio del tiempo . . . . .	31
3.6.1.1.	Raíz media cuadrática: RMS . . . . .	31
3.6.1.2.	Valor absoluto medio: VAM . . . . .	31
3.6.1.3.	Valor absoluto integrado: VAI . . . . .	32
3.6.1.4.	Longitud de la forma de onda: LFO . . . . .	32
3.6.1.5.	Cruces por cero: CPC . . . . .	32
3.6.1.6.	Cambios de pendiente en la señal: CPS . . . . .	32
3.6.2.	Características en el dominio de la frecuencia . . . . .	33
3.6.2.1.	Media de la primera derivada de la FI: MDF . . . . .	34
3.6.2.2.	Características de ancho de banda . . . . .	34
3.6.2.3.	Ancho de banda modulado en amplitud: BAM . . . . .	34
3.6.2.4.	Ancho de banda modulado en frecuencia: BFM . . . . .	34
3.6.2.5.	Media de la frecuencia espectral: MNF . . . . .	34
3.6.2.6.	Momento espectral de la densidad espectral de potencia: SMPSD . . . . .	35
3.6.2.7.	Frecuencia pico de la PSD: PKF . . . . .	35
3.7.	Redundancia entre sensores . . . . .	35
3.8.	Selección de características . . . . .	36
3.8.1.	Clasificación de los movimientos por su taxonomía . . . . .	37
3.8.2.	Métodos de selección de características . . . . .	38
3.8.3.	Prueba H de Kruskal-Wallis . . . . .	39
3.8.4.	Test de comparaciones múltiples de Bonferroni . . . . .	40
3.8.5.	Reducción de características . . . . .	43
3.8.6.	Análisis del discriminante lineal no correlacionado (ULDA) . . . . .	43
3.8.6.1.	Gráficos de dispersión . . . . .	49
<b>4.</b>	<b>Algoritmos de clasificación</b> . . . . .	<b>50</b>
4.1.	Reconocimientos de patrones . . . . .	50
4.2.	Algoritmos de clasificación . . . . .	51
4.2.1.	K-vecinos más cercanos . . . . .	51
4.2.2.	Máquinas de soporte vectorial . . . . .	52
4.2.3.	Árboles de decisión . . . . .	53
4.3.	Métricas de clasificación . . . . .	54
4.3.1.	Matriz de confusión . . . . .	54
4.3.2.	Exactitud . . . . .	55
4.3.3.	Precisión . . . . .	55
4.3.4.	Sensibilidad . . . . .	55
4.3.5.	Puntaje F1 . . . . .	55
<b>5.</b>	<b>Resultados</b> . . . . .	<b>56</b>
5.1.	Resultados utilizando 1 sensor . . . . .	57
5.2.	Resultados utilizando 3 sensores . . . . .	58
5.3.	Resultados utilizando 5 sensores . . . . .	59
5.4.	Matrices de confusión . . . . .	60
5.4.1.	Transformada Wavelet discreta . . . . .	60
5.4.2.	Descomposición de modo variacional . . . . .	61
5.4.3.	Descomposición de modos empíricos por conjuntos . . . . .	62
5.4.4.	Señal original: Sin descomposición . . . . .	63
<b>6.</b>	<b>Conclusiones</b> . . . . .	<b>64</b>

<b>Anexos</b>	<b>73</b>
6.1. Sistema de adquisición de señales sEMG . . . . .	73
6.2. Desarrollo de la prótesis de mano . . . . .	76

# Índice de tablas

3.1. Ejercicios de la base de datos DB2. . . . .	12
3.2. Niveles de descomposición y las subseñales generadas por sensor individual. . . . .	36
3.3. Número de subseñales después de efectuar el ventaneo de la señal. . . . .	36
3.4. Número de muestras generadas para cada uno de los tamaños de ventana. . . . .	36
3.5. Valor $p$ de las diferentes características tiempo-frecuencia en el análisis DWT. . . . .	42
3.6. Valor $p$ de las diferentes características tiempo-frecuencia en el análisis EEMD. . . . .	42
3.7. Valor $p$ de las diferentes características tiempo-frecuencia en el análisis VMD. . . . .	42
5.1. Valores de exactitud para el algoritmo de DT utilizando 1 sensor sEMG. . . . .	57
5.2. Valores de exactitud para el algoritmo de SVM utilizando 1 sensor sEMG. . . . .	57
5.3. Valores de exactitud para el algoritmo de DT utilizando 1 sensor sEMG. . . . .	57
5.4. Valores de exactitud para el algoritmo de KNN utilizando 3 sensores sEMG. . . . .	58
5.5. Valores de exactitud para el algoritmo de SVM utilizando 3 sensores sEMG. . . . .	58
5.6. Valores de exactitud para el algoritmo de DT utilizando 3 sensores sEMG. . . . .	58
5.7. Valores de exactitud para el algoritmo de KNN utilizando 5 sensores sEMG. . . . .	59
5.8. Valores de exactitud para el algoritmo de SVM utilizando 5 sensores sEMG. . . . .	59
5.9. Valores de exactitud para el algoritmo de DT utilizando 5 sensores sEMG. . . . .	59
5.10. Métricas generales para la clasificación DWT . . . . .	60
5.11. Métricas generales para la clasificación VMD . . . . .	61
5.12. Métricas generales para la clasificación EEMD . . . . .	62
5.13. Métricas generales para la clasificación de la señal original . . . . .	63

# Índice de figuras

2.1. Segmentos que conforman la extremidad superior. . . . .	4
2.2. Motoneurona, unidad motora y potencial de acción de la unidad motora. . . . .	6
2.3. Taxonomía propuesta por Cutkosky para agarre de potencia y de precisión. . . . .	10
3.1. a) Movimientos básicos para los dedos y la muñeca b) movimientos de agarre y funcionales c) patrones de fuerza. . . . .	13
3.2. Posición de los electrodos para la adquisición de las señales sEMG. . . . .	13
3.3. Señales sEMG de las 6 repeticiones del movimiento 1 (imagen 18, Figura 3.1). . . . .	14
3.4. Señales sEMG de las 6 repeticiones del movimiento 21 (imagen 38, Figura 3.1). . . . .	14
3.5. Señales sEMG de las 6 repeticiones del movimiento 24 (reposo). . . . .	15
3.6. Diagrama del sistema de clasificación de gestos. . . . .	16
3.7. Preprocesamiento de las señales: Filtrado para la eliminación de ruido. . . . .	17
3.8. Resultados de la etapa de filtrado. . . . .	19
3.9. Comparación de las señales sEMG originales y las sEMG filtradas. . . . .	19
3.10. Preprocesamiento de las señales: Normalización. . . . .	20
3.11. Descomposición mediante la transformada Wavelet discreta . . . . .	21
3.12. a) DWT para $j$ niveles de descomposición b) Árbol de descomposición por DWT para tres niveles de descomposición. . . . .	22
3.13. Descomposición de la señal sEMG en 5 niveles mediante la DWT utilizando la Wavelet db7. . . . .	23
3.14. Diagrama de flujo para llevar a cabo la descomposición de modos empíricos (EMD). . . . .	25
3.15. Descomposición EEMD de una señal sEMG con sus 12 $IMF_k$ . . . . .	26
3.16. Descomposición de Modo Variacional con sus 5 VMF y sus respectivos espectros en frecuencia. . . . .	29
3.17. Ventaneo de las subseñales mediante ventanas de tiempo de 300 ms. . . . .	30
3.18. Superposición de señales EMG en la electromiografía de superficie. . . . .	35
3.19. Los 23 movimientos de la mano con objetos de uso común . . . . .	37
3.20. Movimientos de la mano clasificados en 6 grupos taxonómicos. . . . .	38
3.21. Diagrama de cajas de las distribuciones de datos de las características que no son útiles en la clasificación de los movimientos de la mano. . . . .	41
3.22. Diagrama de cajas para las distribuciones de datos de características que tienen la capacidad discriminatoria en la clasificación de los movimientos de la mano. . . . .	41
3.23. Gráfico de dispersión para ilustrar la reducción de la alta dimensionalidad del conjunto de características para cada método de descomposición sin la implementación del ventaneo. . . . .	45
3.24. Gráfico de dispersión para ilustrar la reducción de la alta dimensionalidad del conjunto de características para cada método de descomposición con la implementación del ventaneo con una ventana de 300 ms. . . . .	46
3.25. Gráfico de dispersión para ilustrar la reducción de la alta dimensionalidad del conjunto de características para cada método de descomposición con la implementación del ventaneo con un tamaño de ventana de 500 ms. . . . .	47

3.26. Gráfico de dispersión para ilustrar la reducción de la alta dimensionalidad del conjunto de características para las señales sEMG sin llevar a cabo ningún método de descomposición de señales implementando el ventaneo de la señal para 300 <i>ms</i> y 500 <i>ms</i> . . . . .	48
4.1. Clasificación de un dato por el método KNN. . . . .	51
4.2. Clasificación por SVM para dos clases (clasificación binaria). . . . .	52
4.3. Matriz de confusión para 2 clases. . . . .	54
5.1. Matriz de confusión para la DWT . . . . .	60
5.2. Matriz de confusión para la VMD . . . . .	61
5.3. Matriz de confusión para la EEMD . . . . .	62
5.4. Matriz de confusión para la señal original (sin descomposición) . . . . .	63
6.1. Sensor MyoWare Muscle Sensor (AT-04-001) . . . . .	73
6.2. Diseño de la tarjeta de adquisición de señales sEMG. . . . .	74
6.3. Tarjeta de adquisición de señales sEMG. . . . .	74
6.4. Interfaz de adquisición de señales sEMG. . . . .	75
6.5. Mano protésica Handi Hand . . . . .	76
6.6. Circuito para el control de la mano robótica. . . . .	77

# Capítulo 1

## Introducción

### 1.1. Planteamiento del problema

En la actualidad el número de personas amputadas incrementa anualmente debido de manera fundamental al envejecimiento de la población y que esta presenta algunos problemas crónicos como diabetes y la enfermedad vascular periférica. En el caso de las amputaciones traumáticas producidas por accidentes se observa con claridad que es la población en edad productiva la más afectada con los jóvenes entre 15 y 24 años de edad y del sexo masculino como los que presentan el mayor número de casos con una razón de 5:1 respecto al género femenino [1]. Las amputaciones debido a los accidentes ya sean del ámbito laboral o de la vida rutinaria se catalogan como un evento inesperado en donde la persona transita de un estado físico de salud óptimo a una discapacidad motriz de manera inmediata. De acuerdo con los resultados de la Encuesta Nacional de la Dinámica Demográfica (ENADID) 2018 en México, de las personas de 5 años o más que habitan en el país, 7.7 millones tienen discapacidad. De cada 100 personas con discapacidad, 51 son adultos mayores (60 años o más). De las personas con discapacidad que tienen 15 años o más, 38.5% forman parte de la población económicamente activa [2]. Por lo cual es de gran interés el desarrollo de dispositivos protésicos que permitan a las personas que han sufrido algún tipo de discapacidad retomar e integrarse nuevamente a su vida cotidiana y a las actividades que estas desempeñaban con anterioridad, puesto que una prótesis puede ayudarlos a recuperar cierta movilidad en la extremidad que se ha perdido.

### 1.2. Aplicaciones de las señales EMG a los dispositivos protésicos

Las señales electromiográficas (EMG) reflejan y brindan información acerca del comportamiento del sistema neuromuscular y han tenido un amplio uso en el diagnóstico de trastornos neuromusculares, desarrollo de dispositivos y equipos de rehabilitación, en el uso de interfaces humano-computadora con realidad virtual, dispositivos de telemanipulación, así como en el control de extremidades artificiales y exoesqueletos [3]. El análisis EMG mediante diversas técnicas de procesamiento de señales permiten identificar patrones que pueden ser utilizados en el reconocimiento de gestos, aunado con los avances significativos que presentan tanto los dispositivos de rehabilitación, de robótica, así como en el uso de sensores más potentes que permiten la adquisición de señales EMG de manera más fiable y sencilla hacen que sea posible el desarrollo y mejora de los dispositivos protésicos. Podemos definir el reconocimiento de gestos como la capacidad de reconocer de manera automática movimientos (gestos), así esta capacidad se puede enfocar en reconocer ciertos movimientos de extremidades corporales como los movimientos o capacidades motrices que se pueden efectuar con la mano.

Con la aplicación de estos avances al campo de estudio y desarrollo de dispositivos protésicos basados en el control electromiográfico permitirá a los sujetos que han sufrido alguna amputación de miembros superiores la recuperación parcial de las funcionalidades proporcionadas por esta extremidad. Para esto, el reconocer movimientos o gestos a partir de las señales EMG nos facilita tareas como la de definir la participación muscular en un determinado gesto o movimiento, observar la activación de una zona muscular de un segmento en respuesta a la motricidad de otras extremidades, así como la comparación y el estudio de la biomecánica de una mano real frente a una mano protésica, todo lo anterior desempeña un papel fundamental para lograr este objetivo. Existen diversos análisis y enfoques en el procesamiento y manipulación de las señales EMG que permiten el reconocimiento de diversos movimientos que dotarían a una prótesis de distintas funcionalidades para la manipulación de objetos permitiendo de esta manera el poder realizar diversas actividades en su vida diaria. El amplio uso que las señales EMG proporciona a distintos campos de estudio y de disciplinas entre las que se encuentran el área médica y de rehabilitación, hace que sea factible el uso de este tipo de señales para la generación de comandos de control que permitan la ejecución de gestos o movimientos de una mano protésica y en consecuencia se pueda llegar a una manipulación de objetos de la vida cotidiana.

### **1.3. Hipótesis**

El uso de métodos de descomposición de señales nos puede proporcionar información relevante de las señales EMG de superficie mediante la extracción de características tiempo-frecuencia que modelen su comportamiento y haciendo uso de algoritmos de aprendizaje automático se reconozcan patrones en las señales que permitan la clasificación de movimientos de la mano.

### **1.4. Objetivo General**

Desarrollar una metodología de análisis, caracterización y clasificación de señales EMG de superficie que permita el reconocimiento de movimientos de la mano para ser utilizado en dispositivos protésicos haciendo uso de técnicas de procesamiento de señales tiempo-frecuencia.

#### **1.4.1. Objetivos Específicos**

1. Evaluar la factibilidad de la metodología para obtener métricas cuantitativas para su uso en aplicaciones con dispositivos protésicos.
2. Estudiar la posible relación taxonómica entre los distintos movimientos a clasificar.
3. Evaluar la factibilidad de implementar la metodología con un dispositivo protésico.
4. Desarrollar un dispositivo de adquisición de señales EMG así como la instrumentación necesaria para su integración con la metodología propuesta.

## 1.5. Estructura de la tesis

El contenido de la tesis se estructura de la siguiente manera:

- **Capítulo 1: Introducción**

Se explica la problemática a la cual va enfocado este estudio, dirigiéndose principalmente al reconocimiento de gestos para su implementación en prótesis de mano. Además se brinda las aplicaciones de las señales electromiográficas al campo de estudio de dispositivos protésicos.

- **Capítulo 2: Prótesis con control electromiográfico**

Se da una visión general sobre el desarrollo y evolución de las prótesis, estudios y análisis enfocados al reconocimiento de movimientos de la mano y como la taxonomía juega un papel fundamental al estudiar los movimientos o agarres manuales. De igual manera una descripción de las señales electromiográficas.

- **Capítulo 3: Metodología**

Se explica el proceso y las características de la adquisición de las señales EMG, así como el desarrollo de las etapas de acondicionamiento de la señal, descomposición de la señal, extracción de características para el análisis y modelado de la señal para cada movimiento y la reducción de características para la eliminación de redundancias en las mismas.

- **Capítulo 4: Algoritmos de clasificación**

Se describen los algoritmos de aprendizaje automático empleados en este estudio para realizar la clasificación de movimientos de la mano.

- **Capítulo 5: Resultados**

Se muestran los resultados obtenidos al clasificar los movimientos de la mano mediante el uso de métodos de descomposición de señales así como de distintos algoritmos de clasificación.

- **Capítulo 6: Conclusiones**

Se concluye respecto a la capacidad de clasificar movimientos de la mano y que esta metodología sea utilizada en dispositivos protésicos, la importancia de tener grupos taxonómicos de agarre manual y por último trabajo a futuro.

- **Anexos:**

Se proporciona información sobre el desarrollo del dispositivo electrónico y de la interfaz gráfica que permitirá la adquisición de señales sEMG así como también del desarrollo de la prótesis del proyecto Handi Hand.



## Capítulo 2

# Prótesis con control electromiográfico

### 2.1. La extremidad superior

En la anatomía del cuerpo humano se tienen extremidades superiores e inferiores, la extremidad o miembro superior se caracteriza por su movilidad y acciones motoras como la prensión, manipulación y agarre de objetos, estas características son especialmente relevantes en el caso de la mano cuando se realizan diversas actividades, la extremidad superior se fija a la parte superior del tronco y se compone de cuatro segmentos principales: hombro, brazo, antebrazo y mano [4]. La figura 2.1 muestra de manera gráfica los segmentos que conforman la extremidad superior.

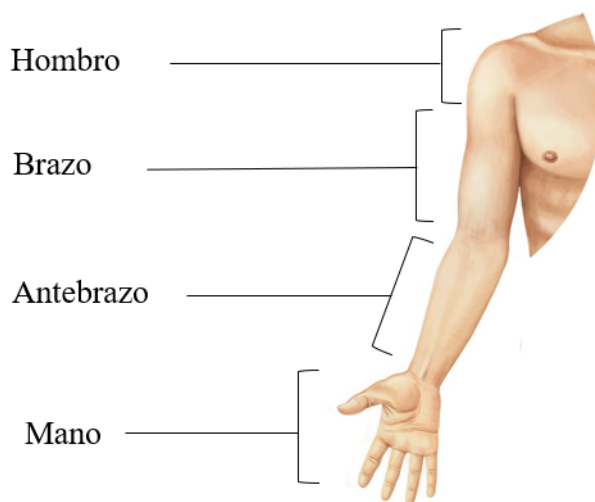


Figura 2.1: Segmentos que conforman la extremidad superior.

Las prótesis de mano buscan replicar las capacidades y funcionalidades que proporciona este segmento de la extremidad superior. Debido a las diversas funciones que se pueden llevar a cabo con este segmento, como lo son: sentir (sentido del tacto), sujetar, manipular y proteger resulta ser la más importante de todas. Esta importancia radica en que desempeña funciones tanto sensoriales, de ejecución, de protección y de orientación con gran precisión. Todo esto plantea un reto el cual es el desarrollar una prótesis de mano que tenga todas las retroalimentaciones sensoriales para poder sentir y ejecutar movimientos o acciones lo más cercano a una mano real, ya que este tipo de percepción sensorial es de vital importancia para efectuar las funcionalidades y actividades de manera correcta, la percepción de las características del medio como son: el

tamaño del objeto, su peso, su consistencia o textura, temperatura así como su posición en la escena y el contexto es crucial para llevar a cabo la manipulación de objetos así como el poder realizar cualquier tipo de actividad o movimiento de la manera más natural posible. Gracias a los avances tanto en las técnicas de procesamiento de señales y en el desarrollo de sensores más potentes que permiten una adquisición de señales de manera más fiable hacen que sea posible la mejora de los dispositivos protésicos permitiendo que estos puedan tener un control basado en el reconocimientos de gestos mediante las señales electromiográficas de superficie. El poder utilizar este tipo de señales presenta algunas ventajas gracias a su fácil implementación para ser registradas y que se pueden obtener múltiples señales EMG de distintos músculos. Todo lo anterior hace que personas que presentan alguna amputación de miembros superiores puedan retomar y mejorar en gran medida su calidad de vida ya que con el uso de una prótesis con control electromiográfico pueden recuperar de manera parcial funcionalidades y capacidades perdidas a causa de la amputación.

## 2.2. Señales electromiográficas

Las señales biomédicas son un conjunto de señales que representan una variable física relevante, las cuales son originadas en alguna zona del cuerpo humano y que son usadas en el diagnóstico e investigación médica. Dicha señal es una función del tiempo que puede describirse en términos de su amplitud, frecuencia y fase. Las señales electromiográficas forman parte de este conjunto de señales las cuales miden la actividad eléctrica generada por los músculos durante su contracción representando así una actividad neuromuscular [5]. El sistema nervioso controla la actividad muscular (contracción/reposo) mediante las motoneuronas, las cuales transmiten señales eléctricas para que los músculos se contraigan, con esto las señales EMG son una indicación eléctrica de la activación neuromuscular. Para la obtención de estas señales se tiene que hacer uso de electrodos, los cuales permiten la detección de la actividad eléctrica, dichos electrodos pueden ser insertados en el tejido muscular (electrodos de aguja) o colocarse de manera superficial en la piel justo encima del tejido muscular (electrodos de superficie), permitiendo de esta manera el registro de la actividad e intensidad eléctrica referente a la contracción muscular. Dependiendo de los electrodos a utilizar para la obtención de las señales EMG la electromiografía puede dividirse en dos grupos: (1) Invasiva y (2) No invasiva (superficie).

La electromiografía se puede definir como la detección y análisis del electromiograma (EMG), es decir, del potencial eléctrico producido durante las contracciones musculares y por tanto constituye una prueba para la exploración física y la evaluación de la integridad del sistema motor. Por tanto, la señal EMG es una señal compleja, que está controlada y generada por el sistema nervioso y depende de las propiedades anatómicas y fisiológicas de los músculos además que esta influenciada en su comportamiento por distintos tipos de ruido. La electromiografía de superficie por ser un método no invasivo es muy popular en distintas aplicaciones que no requieran el estudio exhaustivo de un músculo en particular como lo son: la actividad muscular en acciones dinámicas, permitiendo con esto que sea aplicable al análisis biomecánico de gestos, análisis de la marcha, en estudios de fatiga muscular, en medicina del deporte y la ergonomía. Las señales generadas por este método de adquisición brindan información sobre la activación muscular como lo son: la intensidad de la contracción muscular, la manifestación mioeléctrica de la fatiga y el reclutamiento de unidades motoras. Con lo descrito anteriormente la electromiografía de superficie ofrece algunas ventajas: es incruenta y permite analizar simultáneamente distintos músculos en movimiento y en acciones de duración ilimitada. El análisis y procesamiento de la señal electromiográfica proporciona parámetros de amplitud y frecuencia para estudios

descriptivos y comparativos para diversos enfoques de estudio, sin embargo, no permite valorar la musculatura profunda, aporta menos definición y fiabilidad que los electromiogramas de aguja puesto que las señales EMG obtenidas de manera superficial contiene información electromiográfica de los músculos vecinos a la zona en donde se este obteniendo la señal de interés. Se utilizará el término sEMG para hacer referencia a las señales electromiográficas de superficie.

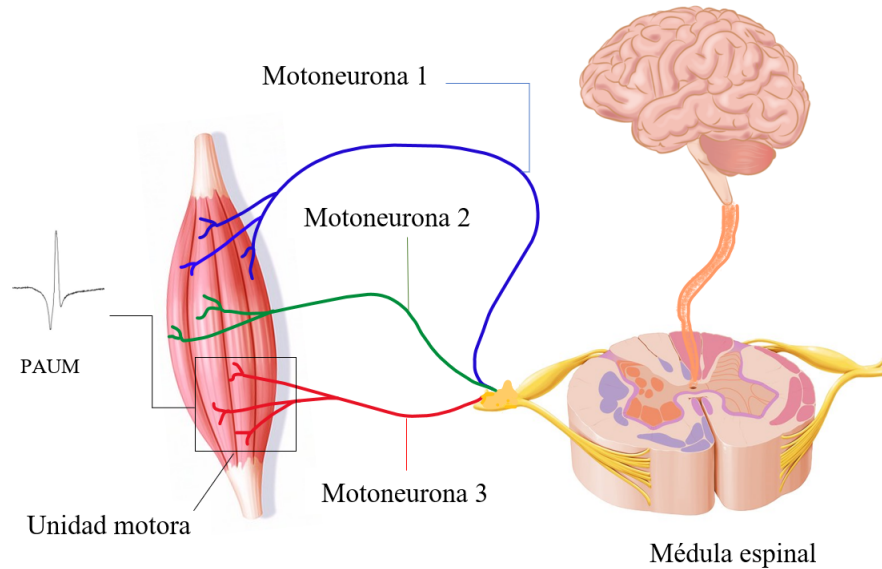


Figura 2.2: Motoneurona, unidad motora y potencial de acción de la unidad motora.

### 2.2.1. La unidad motora

Las unidades motoras (UM) son las entidades funcionales del sistema neuromuscular. Cada UM comprende una única motoneurona y las fibras musculares suministradas por sus ramas axonales. Una vez que se descarga una motoneurona se generan potenciales de acción en sus uniones neuromusculares y luego se propaga a lo largo de todas las fibras musculares hacia las regiones del tendón. La suma de estos potenciales se denomina potenciales de acción de unidad motora (PAUM) los cuales son responsables de la contracción muscular y de la fuerza que esta genera[6]. Hay dos mecanismos principales por los cuales el sistema nervioso permite que un músculo produzca más fuerza: (1) reclutamiento de unidades motoras, en el que se utilizan más UM, y (2) frecuencia de codificación, donde las unidades motoras que ya están reclutadas se disparan a un ritmo más rápido. Cabe resaltar que la contribución de las unidades motoras dependen del músculo o del grupo de músculos a analizar [7]. El número de UM por músculo en los seres humanos puede oscilar entre 100 para un músculo pequeño de la mano y 1000 o más para los músculos grandes de las extremidades. [8].

### 2.2.2. Potencial de acción de la unidad motora (PAUM)

Es la señal eléctrica que es la suma de los potenciales generados por las fibras musculares de una sola unidad motora, en general, las UM se reclutan desde las más pequeñas hasta las más grandes (por ejemplo, las UM con la menor cantidad de fibras se reclutan primero), este reclutamiento ordenado de UM se denominó principio de tamaño. Aunque este principio se ha verificado ampliamente, el reclutamiento de las UM podría estar determinado por el trabajo mecánico de los músculos, la longitud de las fibras musculares y la localización de las fibras

musculares que pertenecen a las UM individuales. Así la señal EMG es la suma aritmética de los potenciales de acción de un conjunto de unidades motoras de la zona muscular de donde se este obteniendo la señal [9]. La figura 2.2 muestra de manera gráfica los componentes necesarios para la generación de una señal EMG.

La estimación de la fuerza muscular individual o global y la identificación de músculos que contribuyen a tareas motoras específicas, o que responden a estímulos de estiramiento, son algunos ejemplos de aplicaciones de la electromiografía de superficie. Cuanto mayor sea la fuerza necesaria para llevar a cabo un objetivo, más PAUM se suman y, por tanto, mayor es la amplitud de las sEMG detectadas en la superficie de la piel. Aunque las variaciones en la amplitud de las señales EMG y la fuerza muscular no son simultáneas, debido al retraso inherente entre la generación de los PAUM y la contracción muscular (también denominado retraso electromecánico), los valores en amplitud de las sEMG reflejan el grado real de activación muscular. Los picos en la EMG intramuscular corresponden a PAUM individuales de cada unidad motora. Está claro entonces, que las UM se reclutaron a lo largo de la contracción, comenzando desde la unidad más pequeña. Por el contrario, los PAUM no son igualmente evidentes en las señales sEMG puesto que los electrodos de superficie son menos selectivos que los electrodos intramusculares o de aguja, la sEMG transmite muchos potenciales de acción de una población de UM. Esta suma de PAUM se ve agravada por el hecho de que el sistema nervioso regula la fuerza muscular de modo continuo e ininterrumpidamente utilizando interacciones adecuadas entre el reclutamiento de UM y la tasa de disparo [6]. Sin embargo, a bajos niveles de contracción, los PAUM individuales pueden ser visibles en la señal sEMG. Por lo tanto, dependiendo de si las señales EMG se registran con electrodos intramusculares o de superficie y de la intensidad de la contracción muscular, se obtienen diferentes vistas de los PAUM.

### 2.3. Análisis sEMG aplicado al reconocimiento de gestos

Las manos protésicas han evolucionado desde los ganchos mecánicos hasta dispositivos sofisticados que funcionan con energía eléctrica y ofrecen un gran número de grados de libertad (GDL). Los primeros dispositivos protésicos se controlaban mediante componentes mecánicos y tenían un número muy limitado de grados de libertad, en donde la mayoría de ellos solo podían efectuar la prensión de algún objeto, hoy en día las prótesis de mano proporcionan una mayor destreza para realizar movimientos más complejos, ya que estas tienen la capacidad de flexión y extensión individual de los dedos, movimiento del pulgar y rotación de la muñeca, además poseen estética lo que hace que sean lo más parecido a una mano real [10].

Los usuarios pueden controlar los dispositivos protésicos modernos con una amplia gama de comandos. El uso efectivo de estos dispositivos, lo cual garantiza la seguridad del usuario y al mismo tiempo la ejecución de los movimientos de manera natural, requiere comandos para la ejecución de la flexión y extensión de los dedos y de esta manera realizar gestos y acciones. Los comandos del usuario pueden basarse en el movimiento, la actividad neuronal u otros medios. En muchas aplicaciones, los comandos se detectan mecánicamente mediante acelerómetros, técnicas capacitivas o sensores de proximidad que se llevan en el cuerpo. Estos requieren que el usuario mueva sus extremidades, sin embargo, puede no ser posible o conveniente. Alternativamente, los comandos basados en la actividad neuronal se centran en la intención motriz del usuario y pueden ser más intuitivos y naturales, especialmente para las personas con una amputación.

Determinar la intención motora del usuario en función de su impulso neural es lo deseable para un control eficaz de la mano protésica ya que este sería intuitivo y natural, sin requerir que el usuario realice movimientos incómodos o secundarios. Por esta razón, el control de la mayoría

de las manos protésicas se debería basar en el uso de señales sEMG, las cuales proporcionan información sobre la actividad neural de los músculos y tiene la ventaja de ser una metodología no invasiva. Sin embargo, se tiene que tomar en consideración que las sEMG es un registro inespecífico y burdo de la actividad muscular, mientras que el movimiento de los dedos, los patrones de agarre y los gestos mantenidos son el resultado de combinaciones complejas de contracciones de múltiples músculos en el antebrazo. Existen similitudes significativas entre la activación de los músculos asociados con diferentes movimientos de los dedos o agarres manuales, así la clasificación de sEMG para distinguir entre estas acciones o movimientos previstos resulta ser un desafío.

Hay varias investigaciones que se enfocan en el reconocimiento de las intenciones motoras a partir del análisis sEMG, puesto que son fundamentales para que un dispositivo protésico tenga la capacidad de realizar tareas diarias. Xiao et al. [11] propuso un enfoque basado en el método de descomposición de modo variacional (VMD: *Variational mode decomposition*) y el índice de entropía de permutación compuesta (CPEI: *Compound Permutation Entropy Index*) para la clasificación de 6 movimientos de la mano (pronación y supinación del antebrazo, mano cerrada y abierta, extensión y flexión de la muñeca) obteniendo una precisión promedio del  $94.28 \pm 1.26$  %. De manera similar Wang [12] propuso un método de dimensión de correlación basado en la transformada wavelet para extracción de características y con esto poder clasificar 4 tipos de movimiento del antebrazo, los resultados obtenidos fueron que para el tercer nivel de descomposición la precisión de la clasificación resultante fue del 100 % utilizando dos canales de señales sEMG, por lo cual utilizar esta metodología puede proporcionar información importante en tiempo y frecuencia en las señales sEMG además de ser adecuada para clasificar diversos movimientos o gestos manuales.

Ngeo et al. [13] obtuvieron datos sEMG del antebrazo así como datos cinemáticos de los dedos al realizar tareas de flexión y extensión de dedos múltiples individuales y simultáneos, utilizaron y evaluaron una red neuronal artificial de retroalimentación rápida y un regresor del proceso gaussiano no paramétrico para estimar la cinemática compleja de los dedos obteniendo una precisión del  $85\% \pm 0.07$ ,  $78\% \pm 0.06$  y  $73\% \pm 0.04$  para los grados de libertad de las articulaciones de los dedos metacarpofalángica, interfalángica proximal e interfalángica distal respectivamente. Zhang et al. [3] extrajeron cuatro características en el dominio del tiempo en las señales sEMG (cruces por cero, diferencia absoluta media, valor absoluto medio y cambios de pendiente en la señal) y usaron un modelo generativo, Deep Belief Network (DBN) para hacer la clasificación de cuatro clases de movimientos en base a la acción realizada los cuales son: movimientos normales/agresivos para la mano y normales/agresivos para las piernas. Se obtuvo un rendimiento en la clasificación del  $90.66 \pm 1.47$  %. Un DBN es un algoritmo de aprendizaje profundo y rápido que puede encontrar un conjunto de pesos óptimos rápidamente, incluso en redes neuronales profundas con muchas capas ocultas, así el modelo DBN que propusieron tiene el potencial de aplicarse en el diseño de interfaces de usuario basadas en sEMG.

Rahimian et al. [14] propone el modelo de reconocimiento híbrido (HRM: *Hybrid Recognition Model*) y el modelo de red convolucional temporal (TCNM: *Temporal Convolutional Network Model*) para realizar el reconocimiento de gestos con las manos a través de señales de electromiografía de superficie multicanal. El objetivo de este estudio fue el de mejorar la precisión de los sistemas mioeléctricos que se pueden utilizar para realizar una interfaz precisa y resistente para el control electromiográfico de los sistemas neurorobóticos. Ellos utilizaron la base de datos Ninapro DB2 para evaluar su sistema propuesto obteniendo un rendimiento en la clasificación de gestos del 98.01 % para el reconocimiento de 17 gestos de la mano.

Reaz et al. [5] realiza un estudio sobre distintas técnicas que van desde la detección, procesamiento y clasificación de las señales sEMG para poder utilizarlas en diversas aplicaciones. Este plantea que debido a la superposición de los PAUM de las múltiples unidades motoras al momento de realizar una actividad, es necesario utilizar métodos de descomposición de la señal para obtener información multiresolución de las señales para posteriormente poder ser analizadas y obtener una mejora al momento de realizar la clasificación.

Torres et al. [15] utilizó 5 métodos de descomposición de señales para la detección y clasificación de desórdenes neuromusculares. Los métodos empleados fueron: descomposición de modos empíricos (EMD: *empirical mode decomposition*) la descomposición de modos empíricos por conjuntos (EEMD: *Ensemble empirical mode decomposition*), la descomposición completa de modo conjunto (CEEMD: *Complete ensemble mode decomposition*), la transformada wavelet empírica (EWT: *empirical wavelet transform*) y la descomposición de modo variacional (VMD: *Variational Mode Decomposition*). Por otra parte, mediante el uso de algoritmos de aprendizaje automático como el análisis del discriminante lineal (LDA: *Linear discriminant analysis*), k vecinos más cercanos (KNN: *K Nearest-Neighbor*) y árboles de decisión, se realizó la clasificación y detección de estos desórdenes en donde se observó que utilizando la EEMD y el algoritmo KNN se presenta una precisión del 99.5%. Con estos resultados se puede considerar que la EEMD es una buena metodología para la descomposición de la señal sEMG y que esta pueda ser aplicada al reconocimientos de movimientos junto con algoritmos de aprendizaje automático.

Atzori et al. [16–18] desarrolló una base de datos para ser utilizada como un recurso para realizar investigaciones y evaluaciones respecto a prótesis controladas con inteligencia artificial. Este proyecto nombrado como Ninapro contempla varias bases de datos con distintos enfoques entre los cuales se encuentra una base de datos con movimientos y tareas con objetos comunes de la vida cotidiana manipulados con la mano, la cual podría ser tomada de referencia para el reconocimiento de gestos para el control de una prótesis. Kuzborskij et al. [19] utilizó esta base de datos para clasificar 52 movimientos pertenecientes a distintas tareas obteniendo una precisión en la clasificación del 70%.

## 2.4. Taxonomía de la mano

En robótica y en el campo de los dispositivos protésicos la taxonomía es un método para organizar la variedad de tipos de prensión humana, y los parámetros utilizados en esta organización revelan algunos de los factores que influyen en la elección de cierto tipo de prensión. El sistema humano utiliza conocimientos codificados en forma de reglas para deducir la comprensión más adecuada en base a las descripciones de objetos y a la tarea a realizar. Al construir la base de reglas, aprendemos de las propiedades y características importantes de los objetos y las tareas [20]. Una taxonomía de los movimientos de las manos es importante para varios campos científicos, incluidos la robótica, las prótesis, la fisiología y la rehabilitación, así un modelado adecuado del agarre humano y de los movimientos de las manos es fundamental. En robótica y prótesis puede ser útil para comparar la funcionalidad de manos robóticas con respecto a manos humanas reales. Sin embargo, la mano humana puede realizar un número amplio de movimientos, por lo tanto estructurar y organizar los agarres y movimientos de las manos en una taxonomía jerárquica puede ser útil para comprender mejor la manera en que interactúan las manos con diferentes objetos, así como para analizar y evaluar dispositivos que intentan imitarlos. En el campo de las prótesis se han desarrollado manos mioeléctricas muy avanza-

das desde un punto de vista mecánico [21]. El diseño de prótesis de mano y el control para su movimiento han sido de gran interés para el área médica y de rehabilitación ya que este es aplicado a personas que han perdido esta extremidad permitiéndoles recuperar funcionalidades y movimientos de la mano. En la actualidad gracias a los numerosos desarrollos de prótesis de mano estas han tenido un progreso significativo tanto en su diseño de construcción, su mecánica y en su control; sin embargo, los problemas que se tienen hoy en día derivan de la capacidad para desarrollar algoritmos que permitan resolver cálculos en tiempo real en el procesamiento multisensorial y motor. La meta u objetivo principal del campo de las prótesis de mano, al igual que la rehabilitación robótica, es el construir un dispositivo capaz de realizar movimientos de la mano y que puedan manipular una amplia variedad de objetos con el fin realizar tareas de la vida diaria y con la mayor naturalidad posible.

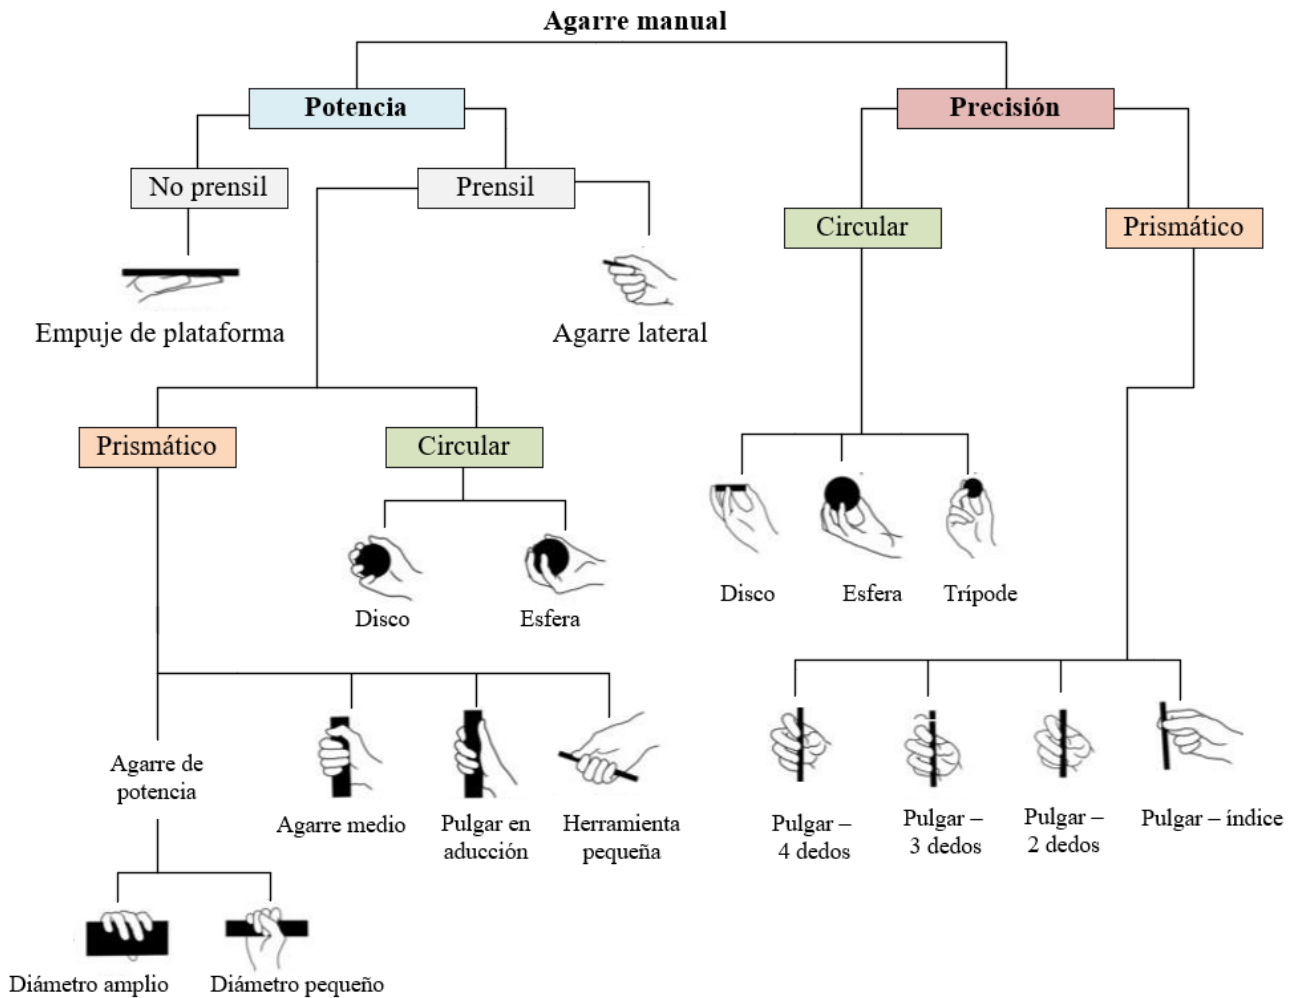


Figura 2.3: Taxonomía propuesta por Cutkosky para agarre de potencia y de precisión.

Al estudiar los movimientos de agarre y de manipulación de la mano existen dos enfoques: (1) enfoque basado en el conocimiento fundamentado principalmente en estudios empíricos de agarre y manipulación humana y (2) enfoques analíticos basados principalmente en modelos físicos del proceso de manipulación. El primero de ellos estudia el agarre por humanos y animales, los únicos sistemas de agarre exitosos en nuestra experiencia puesto que son sistemas naturales que nos permiten aprender de ellos y desarrollar sistemas artificiales que traten de imitarlos, sin embargo muchas veces los métodos naturales del movimiento de la mano del ser humano no

resulta ser adecuado para los sistemas mecánicos. Por el contrario, el enfoque analítico modela la manipulación y el agarre desde los principios físicos. Las interacciones entre la mano y el objeto agarrado se modelan en términos de movimientos y fuerzas, utilizando las leyes de la física, pero esta al ser altamente difícil y complicada hace que se requieran muchas simplificaciones.

Napier et al. [22] propuso la construcción de una taxonomía basada en enfoques y justificaciones cualitativas, las cuales deben de ser categorizadas por la función del movimiento. El esquema de Napier hace una división entre tareas de potencia y de precisión, la cual sirvió de referencia en investigaciones posteriores. Cutkosky [20, 23] organizó 16 agarres manuales en un árbol jerárquico de acuerdo con la adaptabilidad requerida por las tareas. Los agarres se caracterizaron utilizando varias medidas cualitativas (como el cumplimiento de la tarea, conectividad, isotropía de agarre, resistencia y otros parámetros) y se dividieron en tareas de potencia y precisión. En la figura 2.3 se puede observar la taxonomía propuesta por Cutkosky y como la geometría del objeto se combina para dictar la elección del agarre, además que las percepciones táctiles son también una fuente de información valiosa para desempeñar y seleccionar el agarre manual.

## 2.5. La mano como elemento de percepción háptica

El sentido del tacto nos conecta físicamente con el mundo exterior. La percepción háptica se refiere a nuestra capacidad para captar información a través del tacto. Nosotros exploramos nuestro entorno de manera activa mediante el uso de nuestras manos, dedos y el cuerpo. Con las capacidades motoras de la mano podemos extraer características importantes necesarias para identificar y hacer uso de objetos o herramientas. Así, un sistema háptico esta diseñado para procesar las propiedades materiales de objetos y superficies mediante sistemas aferentes cutáneos y cinestésicos. La percepción háptica a menudo se le conoce como percepción táctil y hace referencia a las sensaciones que se obtienen al tocar elementos del mundo exterior o del medio físico donde nos encontremos [24]. El tacto y la presión son detectados mediante la estimulación mecánica de la piel, la mano es el segmento principal para adquirir información táctil a través de mecanorreceptores los cuales transforman la energía mecánica en energía electroquímica para crear una señal neural. En la piel se ha identificado cuatro tipos de mecanorreceptores para responder a cuatro tipos de estímulos táctiles. Los corpúsculos de Meissner son receptores que muestran la respuesta a cambios de la textura y vibraciones lentas, los discos de Merkel son terminaciones que muestran respuesta a presión y tacto sostenidos al igual que los corpúsculos de Ruffini donde ambos son de adaptación lenta y los corpúsculos de Pacini son los receptores que nos muestran respuesta a una presión profunda y vibración rápida [25].

Con lo anterior se puede observar que la percepción háptica es fundamental para la descripción del medio y del entorno donde estamos, ya que ella nos brinda una retroalimentación para ser capaces de describir un objeto y con las características que este posee poder definir una intención motora más precisa tanto en fuerza como en la ejecución de la tarea a realizar, así se obtendría una mejor manera de manipular un objeto o herramienta. Dado que los sistemas hápticos pueden proporcionarnos información sobre los entornos mediante el sentido del tacto humano y la retroalimentación de fuerza, las investigaciones y aplicaciones hápticas recientes han ganado una atención significativa en muchos temas como prótesis de mano, robótica quirúrgica, realidad virtual, rehabilitación, capacitación médica, simuladores y telerobótica.



## Capítulo 3

# Metodología

### 3.1. Base de datos EMG

Para realizar el reconocimiento de movimientos, en este estudio se tomó como referencia la base de datos Ninapro (Non Invasive Adaptative Prosthetics), el cual es un proyecto que contempla 10 bases de datos y es un punto de referencia para el análisis, investigación y evaluación sobre manos robóticas y protésicas controladas con inteligencia artificial. La base de datos contempla datos de electromiografía, cinemática, inercia, datos visuales, clínicos y neurocognitivos. Para desarrollar este estudio se seleccionó la base de datos nombrada como DB2 [18], la cual incluye la actividad muscular de 40 sujetos intactos, de los cuales 28 son hombres y 12 mujeres en un rango de edad entre los  $29.9 \pm 3.9$  años, del total de participantes 34 de ellos son diestros y 6 son zurdos. Este conjunto de datos esta dividido en tres ejercicios B, C y D con un tipo y número distintos de movimientos como se muestra en la tabla 3.1 y existen un total de 49 movimientos distintos y uno de reposo.

Tabla 3.1: Ejercicios de la base de datos DB2.

DB2		
Ejercicio	Num. de movimientos	Tipo de movimiento
B	17	8 configuraciones isométricas e isotónicas de la mano y 9 movimientos básicos de la muñeca
C	23	23 movimientos de agarre y funcionales (los objetos cotidianos que se le presentan al sujeto para agarrar son para imitar las acciones de la vida diaria)
D	9	9 patrones de fuerza

A pesar de que los datos están basados en electromiografía de sujetos intactos, estos pueden ser utilizados como una medida aproximada para el reconocimiento y clasificación de gestos de personas con amputación, así estos datos permitirán replicar las funcionalidades y capacidades que la mano nos proporciona, se optó por seleccionar la base de datos referente al ejercicio C puesto que los 23 movimientos que conforman a este ejercicio buscan imitar las acciones y actividades que realizamos en la vida cotidiana con la mano y con objetos de uso común como se muestra en la figura 3.1.

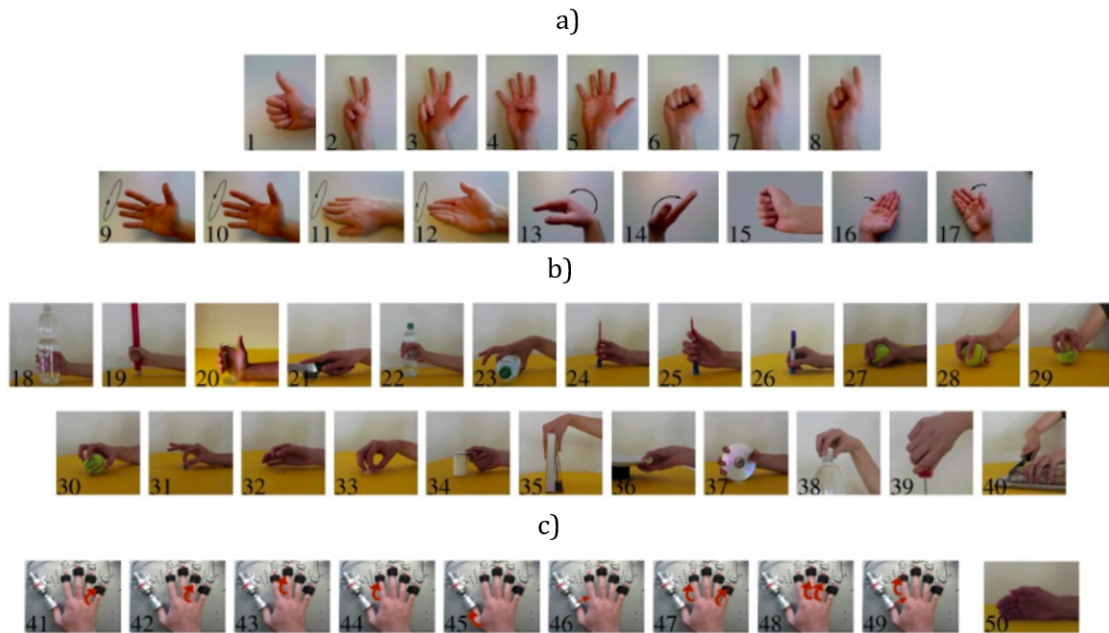


Figura 3.1: a) Movimientos básicos para los dedos y la muñeca b) movimientos de agarre y funcionales c) patrones de fuerza.

### 3.1.1. Adquisición de las señales sEMG

La adquisición de la actividad muscular mediante las señales sEMG fueron adquiridas por medio de 12 electrodos Trigno Wireless (Delsys, Inc, [www.delsys.com](http://www.delsys.com)), los cuales se fijaron utilizando bandas adhesivas estándar. Se colocó una banda elástica hipoalérgica sin látex alrededor de los electrodos para mantenerlos fijos durante el registro de las señales tal como se muestra en la figura 3.2. Así 8 electrodos se colocaron de manera equidistante alrededor del antebrazo para obtener una muestra significativa de los músculos ubicados en la parte proximal del antebrazo, los electrodos 9 y 10 se colocaron en los principales puntos de actividad del músculo extensor común y del flexor común superficial de los dedos, finalmente los electrodos 11 y 12 se colocaron en el bíceps y tríceps respectivamente. Todos estos músculos se seleccionaron en función de su importancia para el control motor de la mano y del antebrazo, dado que estos músculos todavía permanecen en la mayoría de los amputados transradiales [26].




Figura 3.2: Posición de los electrodos para la adquisición de las señales sEMG.

A los 40 sujetos se les instruyó para realizar una serie de movimientos, los cuales se les presentaban en la pantalla de una computadora. Para cada movimiento el sujeto tiene que llevar a cabo seis repeticiones consecutivas donde cada repetición tiene una duración de 5 segundos. Para asegurar una posición consistente al inicio y final de cada una de las repeticiones se alterno entre cada una de ellas una posición de descanso o reposo que tiene una duración de 3 segundos, cada una de las señales sEMG fueron muestreadas a una tasa de 2 kHz.

En base a la figura 3.1 los movimientos seleccionados fueron del número 18 al 40 y de igual manera se incluyó el movimiento de reposo, teniendo un total de 24 movimientos, los cuales fueron renombrados con los números del 1 al 24.




Figura 3.3: Señales sEMG de las 6 repeticiones del movimiento 1 (imagen 18, Figura 3.1).

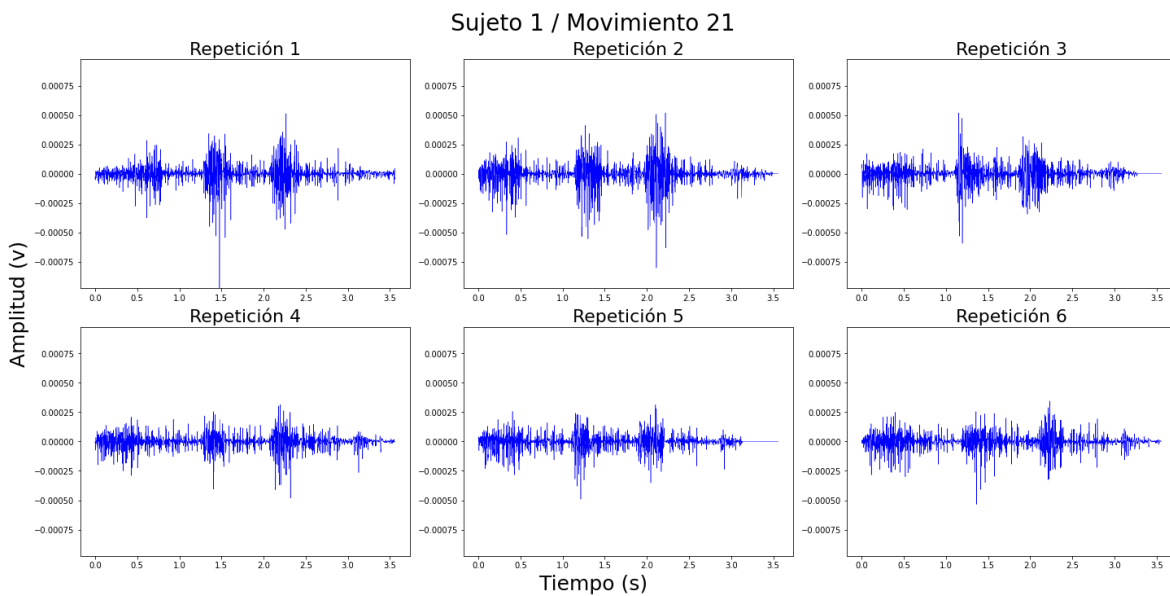


Figura 3.4: Señales sEMG de las 6 repeticiones del movimiento 21 (imagen 38, Figura 3.1).

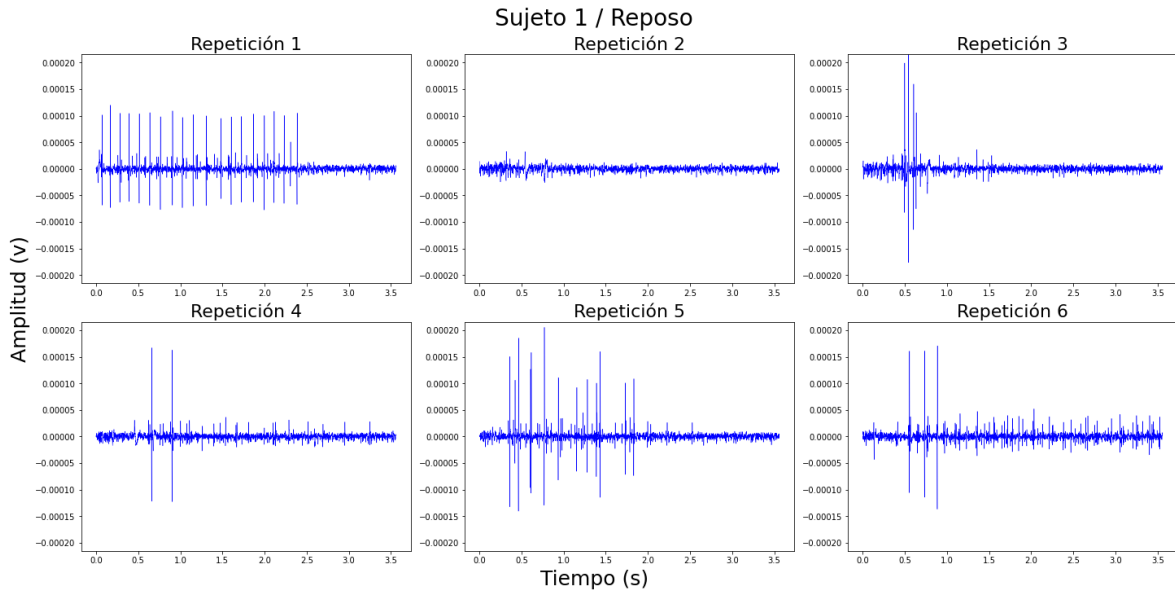


Figura 3.5: Señales sEMG de las 6 repeticiones del movimiento 24 (reposo).

### 3.2. Sistema de clasificación de gestos mediante señales EMG

Una vez seleccionada la base de datos para el reconocimiento de movimientos de la mano se realiza un análisis que permite comparar entre tres métodos de descomposición de señales, el rendimiento y precisión en la clasificación de estos movimientos. En la figura 3.6 se ilustra cada uno de los componentes del sistema para el análisis, descomposición y clasificación mediante las señales electromiográficas. Tomando como entrada una señal sEMG esta ingresa primeramente a una etapa de preprocesamiento que consta de dos subetapas: filtrado y normalización. La primera de ellas posee tres filtros para la eliminación de ruido, que son: un filtro Hampel, Notch y un filtro pasa banda Butterworth. La segunda etapa es la normalización que es crucial para comparar los niveles de actividad muscular entre distintos músculos y entre distintos sujetos. Posteriormente se hace una descomposición de la señal mediante los métodos de la transformada wavelet, descomposición de modos empíricos por conjuntos y descomposición de modo variacional de los cuales se obtienen subseñales que nos brindan información multiresolución. En la etapa de extracción de características a cada subseñal para los tres distintos métodos de descomposición se extraen características en el dominio del tiempo y de la frecuencia obteniendo así un vector de características tiempo-frecuencia que resultan ser necesarias para llevar a cabo la clasificación. Sin embargo, debido a la gran cantidad de características y a la redundancia entre algunas de ellas hace que sea necesario una etapa de selección y reducción de características por medio de la cual solamente se seleccionarán las características que presenten diferencia entre clases. Esta selección se realiza utilizando la prueba no paramétrica Kruskal-Wallis que nos permite probar si un grupo de datos proviene de la misma población. La reducción de características consiste en mapear los vectores de características a una dimensión menor que sea más adecuada para la clasificación. Para el reconocimiento de patrones se utilizaron tres técnicas de aprendizaje automático que fueron: *k*-vecinos más cercanos (KNN: *K-Nearest Neighbors*) por su simplicidad y por que ha demostrado buenos resultados al ser utilizado con señales de electromiografía, máquinas de soporte vectorial (SVM: *Support Vector Machine*) y árboles de decisión (DT: *Decision Trees*).

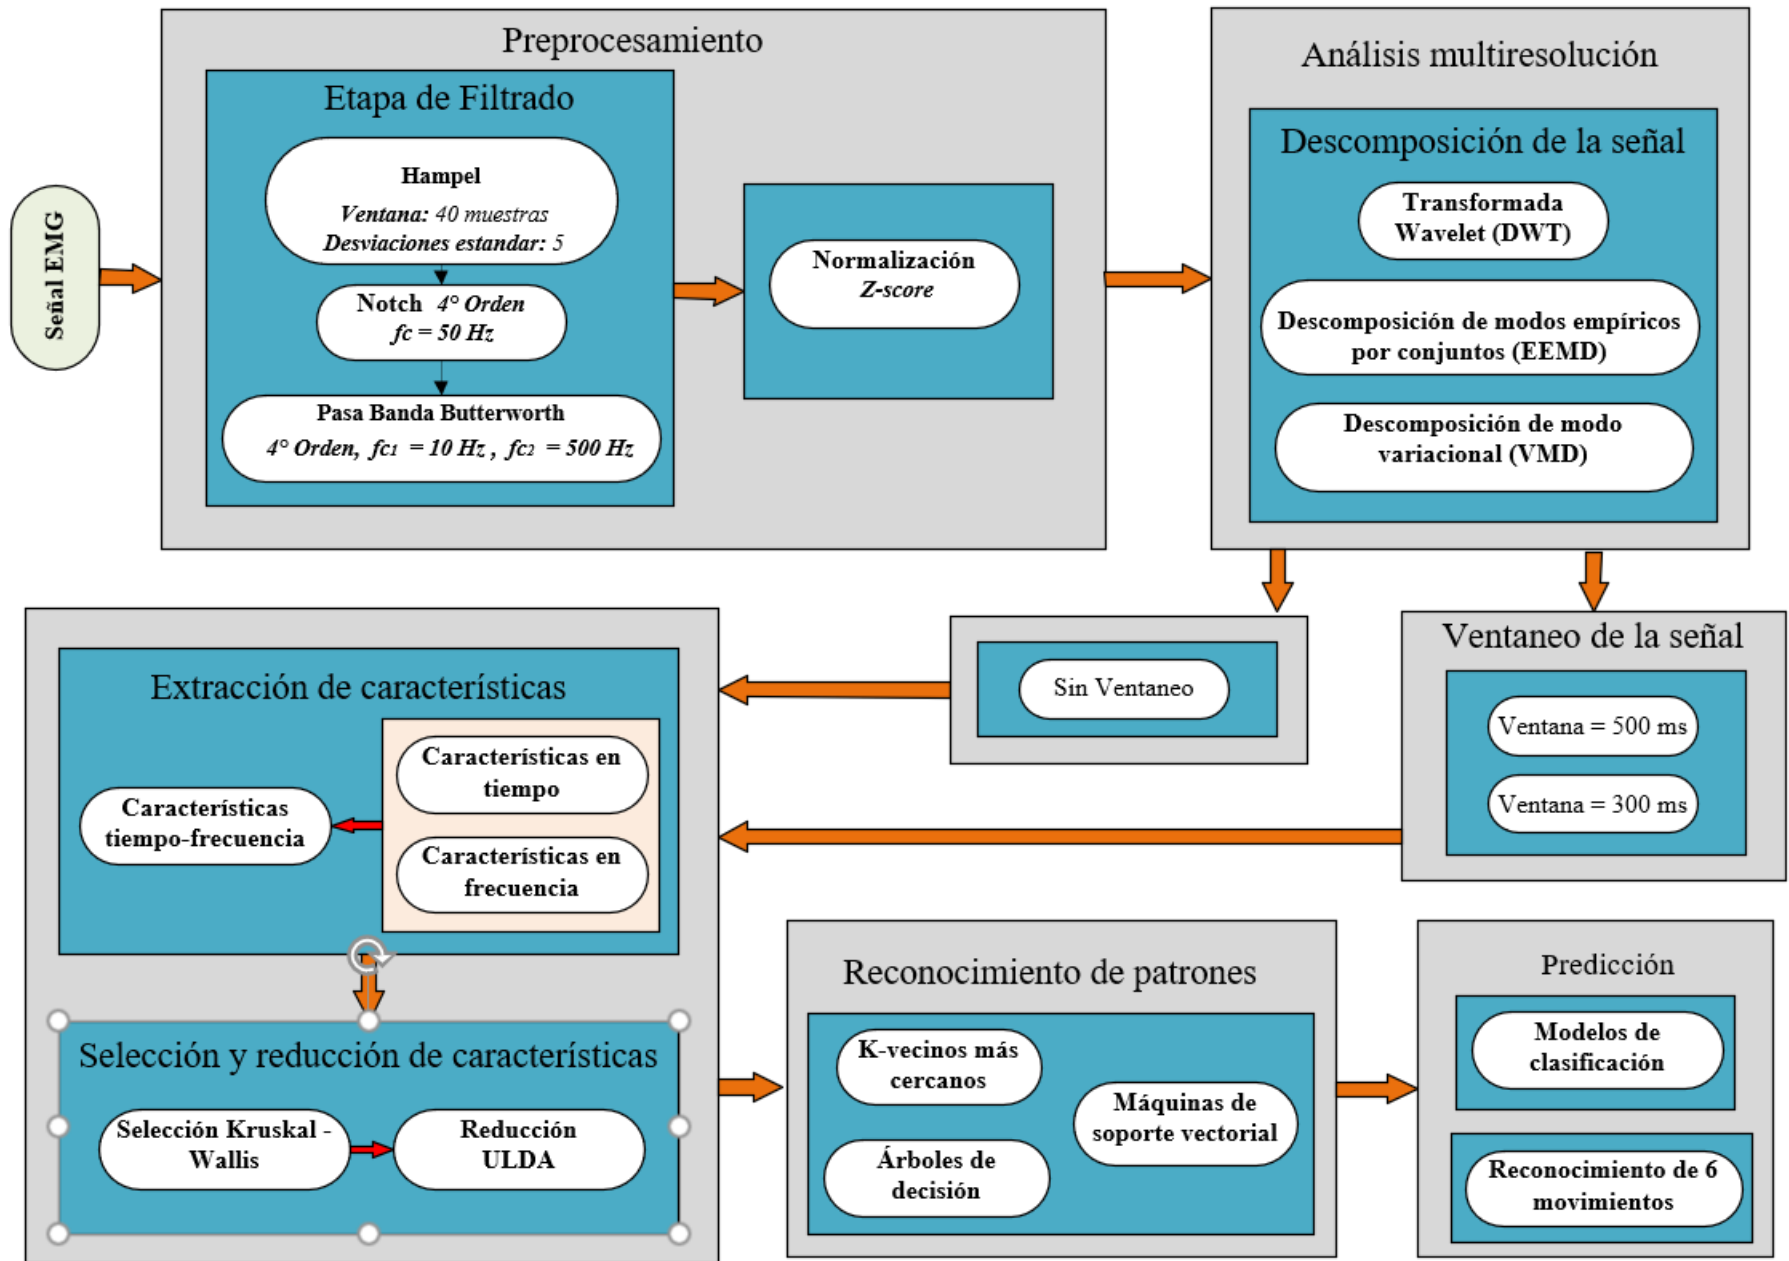


Figura 3.6: Diagrama del sistema de clasificación de gestos.

### 3.3. Preprocesamiento de la señales

#### 3.3.1. Eliminación de ruido: Etapa de filtrado

Previamente al análisis de las señales sEMG se tiene que realizar una etapa de preprocesamiento ya que este tipo de señales son complejas puesto que están contaminadas con distintos ruidos y artefactos que son ajenos a la señal debido al uso del equipo electrónico de adquisición y factores anatómicos y fisiológicos de los músculos y la piel, una señal ruidosa puede afectar el resultado de la extracción de características así como el propósito y objetivo principal del análisis. Los principales ruidos presentes en la señal sEMG son: ruido inherente al equipo electrónico, artefactos por movimientos, ruido del ambiente, Cross Talk (superposición de señales sEMG), inestabilidad inherente a la señal y artefactos electrocardiográficos (ECG) [27]. Por esto las señales sEMG se ven degradadas en su calidad y fiabilidad para realizar cualquier tipo de análisis, para mitigar la influencia de los diversos tipos de ruido se implementa una etapa de filtrado que consta de una serie de filtros en cascada como lo muestra la figura 3.7. Esta etapa esta constituida por tres filtros los cuales son: filtro Hampel, Notch y pasa banda. Al inicio la señal sEMG entra a esta etapa y es filtrada primeramente por el filtro Hampel esto con el fin de atenuar los datos atípicos o anómalos en la señal, posteriormente mediante el uso de un filtro Notch se atenúa la frecuencia de línea que es ocasionada por la red eléctrica, finalmente se limita en banda la señal sEMG para obtener la información más relevante y de interés de esta señal haciendo uso de un filtro pasa banda. A continuación se describe a detalle cada uno de estos filtros.

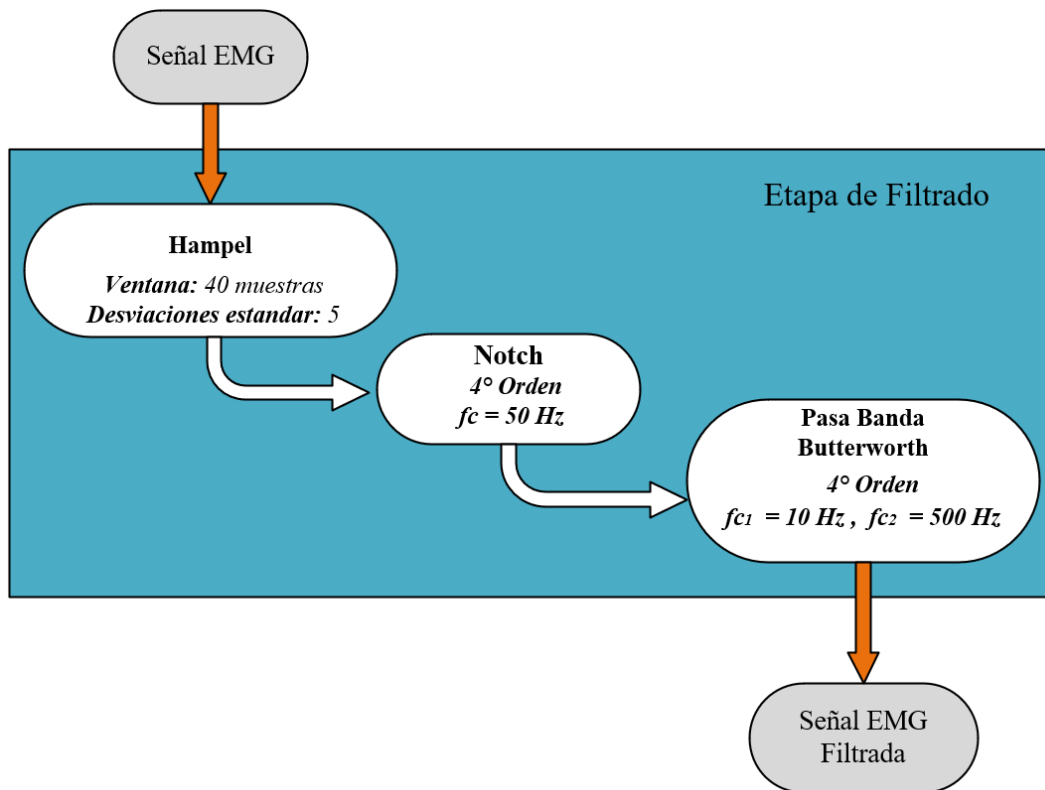


Figura 3.7: Preprocesamiento de las señales: Filtrado para la eliminación de ruido.

### 3.3.1.1. Detección de datos atípicos: Filtro Hampel

Las señales sEMG presentan valores atípicos debido a las interferencias y al ruido, lo cual ocasiona que al momento de realizar la transformada de Fourier se presenten frecuencias en su espectro que afectará los resultados del análisis. Se implementa un filtro Hampel para identificar los valores atípicos o anomalías en los datos de la señal  $(x_1, x_2, \dots, x_N)$ . Este filtro define los valores atípicos como aquellos datos  $x_j$ , cuya diferencia absoluta del valor de la mediana es mayor que un umbral predeterminado como lo muestra la ecuación 3.1.

$$|x_j - x^*| > tS \quad j = 1, 2, \dots, N \quad (3.1)$$

$$S = 1.4286 \text{ mediana } \{|x_j - x^*|\} \quad (3.2)$$

donde  $x^*$  es el valor de la mediana de una secuencia de datos de longitud  $N$ ,  $S$  es la desviación absoluta mediana (DAM) y  $t$  es un valor escalar que se usa como umbral. El valor 1.4286 en la ecuación 3.2 asegura que el valor esperado de  $S$  es igual a la desviación estándar de los datos distribuidos normalmente [28].

Pearson et al. [29] desarrolló un filtro Hampel en el dominio del tiempo para el modelado e identificación de procesos utilizando la estimación DAM para localizar valores atípicos que ocurren dentro de una ventana de tiempo deslizante. Si se detectan valores atípicos en la ventana, se reemplazan por el valor mediano de los datos en la ventana. Por lo tanto, el filtro tiene dos parámetros que pueden ser ajustados, el primero de ellos es el tamaño de la ventana  $L$  y el umbral  $t$ . Se puede observar en la ecuación 3.1 que  $t$  controla el comportamiento del filtro ya que a medida que aumenta el valor de  $t$ , se declaran menos datos como valores atípicos, mientras que una reducción en el valor de  $t$  conduce a un aumento en el número de valores atípicos en la serie de datos. En el extremo, cuando  $t$  tiende hacia 0, el filtro converge al filtro mediano en el que todos los puntos de datos son reemplazados por el valor mediano de la ventana de datos. En la práctica, sin embargo, el valor de  $t$  se fija en aproximadamente 5.0 para  $N$  relativamente grande ( $N > 10$ ) [30], así para identificar de manera óptima los datos atípicos en las señales sEMG el tamaño de la ventana se ajustó a 40 muestras y el valor de  $t$  se fijó en 5.

### 3.3.1.2. Eliminación del ruido y límites del ancho de banda: Filtro Notch y Pasa banda

Posteriormente es necesario la implementación de un filtro rechaza banda o Notch de cuarto orden que permite eliminar la frecuencia de línea inducida por la red eléctrica, la frecuencia de corte de este filtro es de  $50 \text{ Hz}$  debido a las características de la red eléctrica del país en donde fueron adquiridas las señales. El ancho de banda de las señales EMG oscilan entre los  $20 \text{ Hz}$  y  $500 \text{ Hz}$ , así que es necesario delimitar este ancho de frecuencias para obtener la información principal de estas señales. De la misma manera para la eliminación de ruidos como lo son: el ruido inherente al equipo electrónico, a los artefactos por el movimiento y al ruido en el ambiente se implementó un filtro digital pasa banda *Butterworth* de cuarto orden y con frecuencias de corte  $f_{c1} = 10 \text{ Hz}$  y  $f_{c2} = 500 \text{ Hz}$ . Se seleccionaron estas frecuencias puesto que es el rango de frecuencias en que las señales sEMG presentan su información más relevante. La frecuencia de corte  $f_{c1}$  se fijó en  $10 \text{ Hz}$  esto con el fin de eliminar los efectos causados por los movimientos de baja frecuencia al momento de la adquisición de las señales ya sea por el movimiento de los electrodos o al propio movimiento del sujeto.

En la figura 3.8 se observa la implementación de los filtros en cascada así como los resultados obtenidos al aplicar estos filtros sobre la señal sEMG original. En la figura 3.9 se hace una comparación entre la señal sEMG original (contaminada por distintos tipo de ruido) y la señal filtrada.

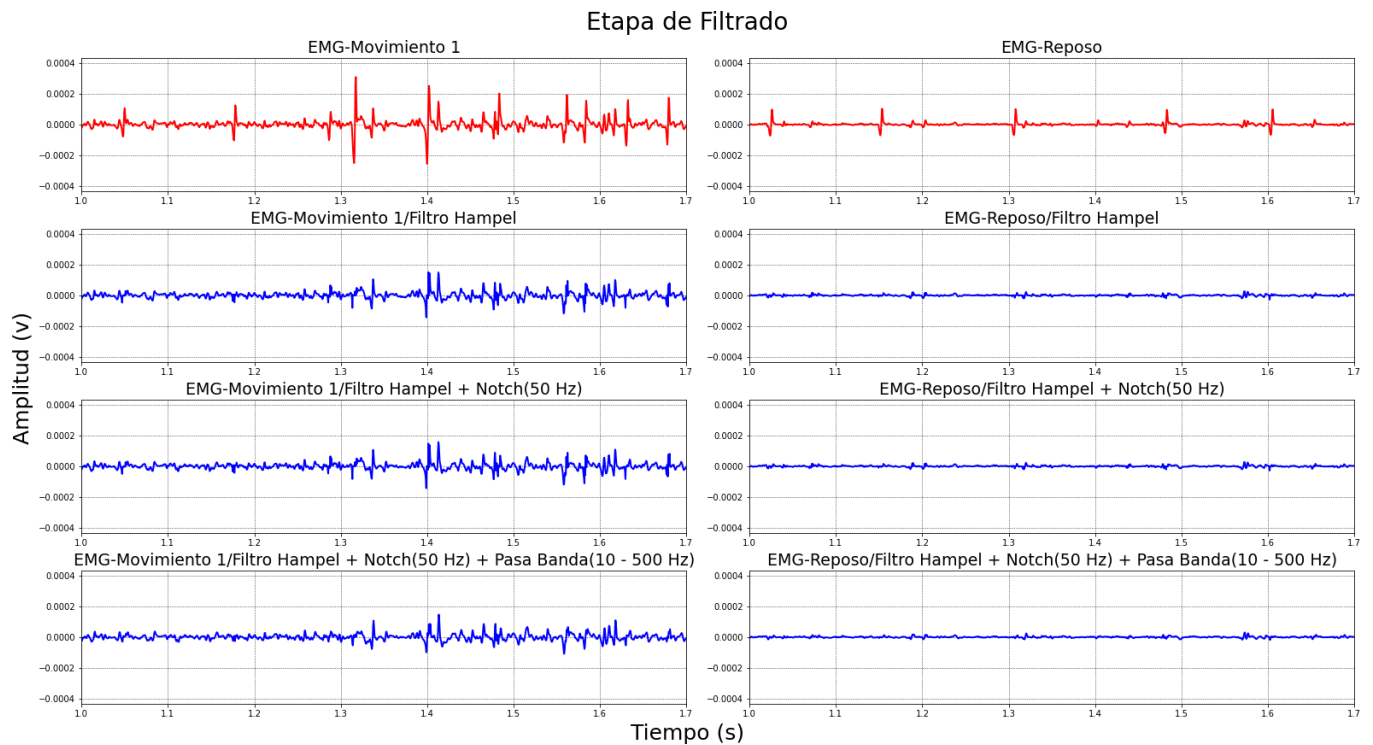


Figura 3.8: Resultados de la etapa de filtrado.

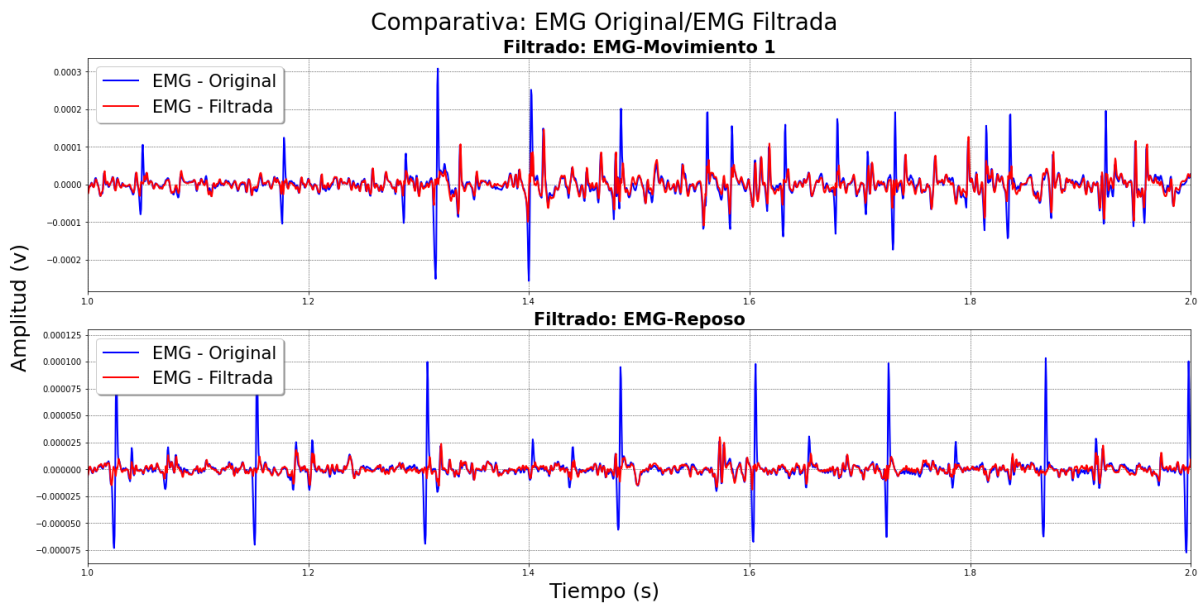


Figura 3.9: Comparación de las señales sEMG originales y las sEMG filtradas.



### 3.3.2. Normalización

Los valores referentes a la amplitud de las señales sEMG tienen deficiencias debido a una amplia variedad de factores que van desde el tipo de electrodos a utilizar, la impedancia de la piel y la colocación de los electrodos, además cualquier información relacionada con el grado de activación muscular es crucial para comparar los niveles de actividad muscular entre distintos músculos y entre distintos sujetos [31]. Para ello, numerosos autores han recomendado una normalización para las señales EMG [32, 33]. En la mayoría de los casos, la actividad EMG se expresa en relación con la de un registro previo de una breve contracción voluntaria máxima isométrica (IMVC: *Isometric Maximum Voluntary Contraction*) realizada a una longitud muscular determinada [34]. Para este caso en lugar de utilizar el enfoque basado en el IMVC se plantea el uso de una normalización de las señales sEMG utilizando el enfoque z-score. Así para una variable aleatoria  $x$  con media  $\mu$  y desviación estándar  $\sigma$  el z-score para la variable  $x$  es:

$$z = \frac{x - \mu}{\sigma} \quad (3.3)$$

El z-score mide la distancia de un punto de datos o información a la media en términos de la desviación estándar. El conjunto de datos estandarizados o normalizados tiene media 0 y desviación estándar 1 además que conserva las propiedades de forma del conjunto de datos original como lo es la asimetría y curtosis.




Figura 3.10: Preprocesamiento de las señales: Normalización.

### 3.4. Análisis para el reconocimiento de gestos

El reconocimiento de gestos así como las metodologías aplicadas para llevar a cabo este objetivo hacen que sea necesario extraer información de las señales sEMG, el reto principal está en seleccionar el análisis adecuado que permite la correcta extracción de información así como en la selección de los distintos parámetros que se necesitan para llevarlo a cabo. La transformada rápida de Fourier (FFT: *Fast Fourier Transform*) ha sido ampliamente usada en el campo de procesamiento de señales para extraer información en el dominio de la frecuencia, sin embargo esta transformación no proporciona ninguna información en el dominio del tiempo. Para solucionar este inconveniente se ideó la transformada de Fourier de tiempo corto (STFT: *Short Time Fourier Transform*) la cual divide la señal original en varias partes de igual longitud mediante el uso de una ventana deslizante antes de aplicar la transformada de Fourier, con esto la STFT nos proporciona información de la señal en el dominio tiempo-frecuencia. El inconveniente de este tipo de análisis es que asume que la señal a tratar tiene la condición de estacionariedad, sin embargo ya que la mayoría de las señales que vemos en la vida real son de naturaleza no estacionaria tal como lo son las señales sEMG no obtendríamos buenos resultados para el reconocimiento de los movimientos. Existen algunas metodologías de descomposición que permiten analizar señales con naturaleza no estacionaria como lo son la transformada Wavelet

discreta, la descomposición de modo variacional y la descomposición de modos empíricos por conjuntos. Para comparar el rendimiento en la clasificación así como encontrar el mejor método de descomposición de señales que permita efectuar el reconocimiento de gestos de la mano se plantearon estos tres métodos de procesamiento de señales que permiten descomponer una señal en subseñales que brindan información valiosa acerca de las características de cada señal sEMG para cada gesto o movimiento. Para efectuar el análisis sEMG multiresolución para el reconocimiento de gestos se propone utilizar los siguientes tres métodos de descomposición:

- Análisis por la Transformada Wavelet Discreta (DWT)
- Análisis por Descomposición de Modos Empíricos por Conjuntos (EEMD)
- Análisis por Descomposición de Modo Variacional (VMD)

### 3.4.1. Análisis por Transformada Wavelet Discreta

Este método de descomposición se realiza mediante el uso de la transformada wavelet discreta (DWT: *Discrete Wavelet Transform*), el cual es un método de análisis tiempo-frecuencia que descompone la señal sEMG en múltiples series de tiempo ortogonales con distintas bandas de frecuencia. La DWT actúa como un banco de filtros, es decir, que se implementa como filtros pasa altas y pasa bajas en cascada, así de esta manera la señal original se divide en varias bandas de frecuencia. El algoritmo de la DWT se podría explicar de la siguiente manera: dada una señal de entrada  $S$  de longitud  $N$  la DWT tendrá como máximo  $\log_2 N$  niveles de descomposición, en el primer nivel de descomposición se obtendrá dos conjuntos de coeficientes: coeficientes de aproximación  $cA_1$  y los coeficientes de detalle  $cD_1$ . Estos coeficientes son obtenidos mediante la convolución de la señal de entrada  $S$  con el filtro pasa altas y el pasa bajas, seguido de una decimación (submuestreo) con lo cual obtendríamos cada uno de los coeficientes respectivamente [35, 36].

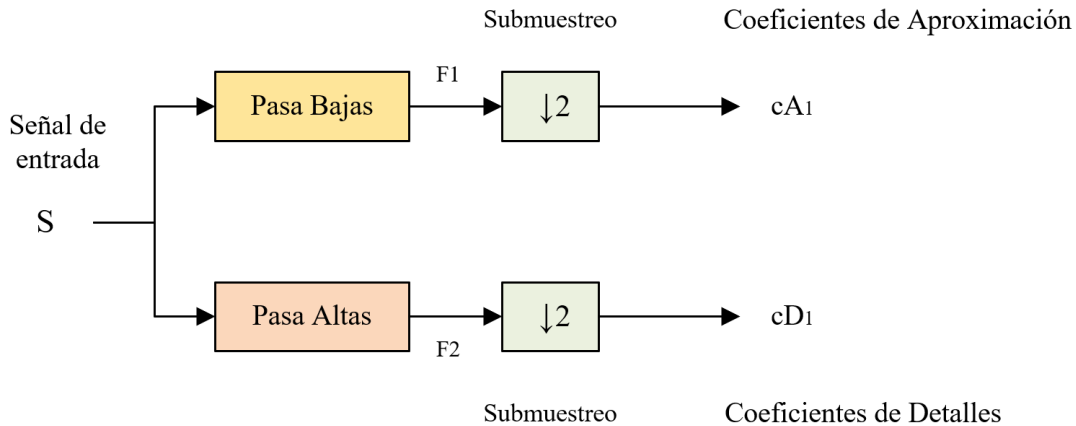


Figura 3.11: Descomposición mediante la transformada Wavelet discreta

La figura 3.11 ilustra la descomposición de la señal de entrada en su primer nivel, en consecuencia para la obtención del segundo nivel los coeficientes de aproximación  $cA_1$  se dividirá en dos nuevos conjuntos de coeficientes siguiendo el algoritmo descrito anteriormente. Ahora se reemplaza la señal de entrada  $S$  por  $cA_1$  y obteniendo los nuevos coeficientes respectivos para el nivel 2 de descomposición:  $cA_2$  y  $cD_2$ , así de manera sucesiva hasta obtener el último nivel. Con lo anterior la señal original ahora se convierte en varias señales, cada una con su respectiva banda de frecuencia. En la figura 3.12 se generaliza el algoritmo para  $j$  niveles de descomposición.

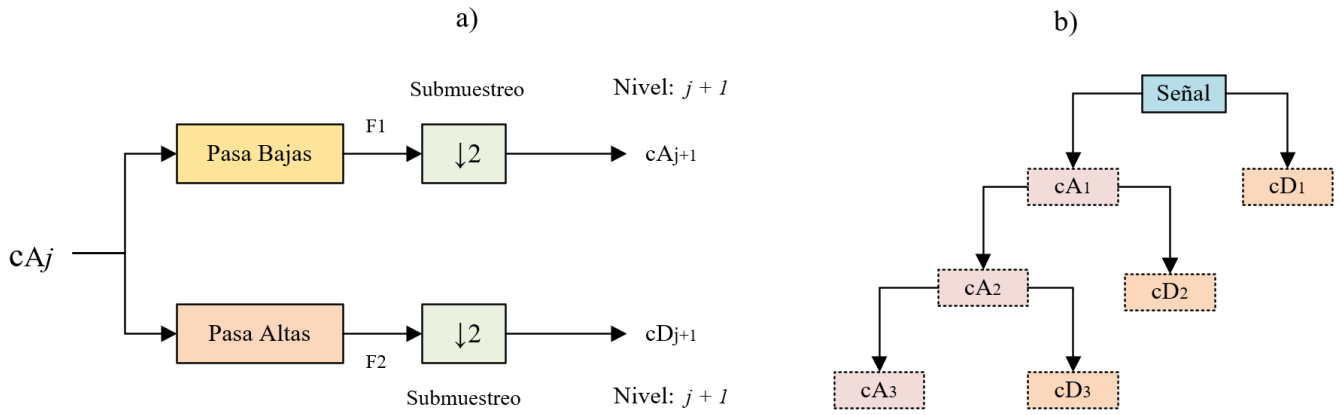


Figura 3.12: a) DWT para  $j$  niveles de descomposición b) Árbol de descomposición por DWT para tres niveles de descomposición.

Mediante la transformada Wavelet tenemos una alta resolución tanto en el dominio del tiempo como en el dominio de la frecuencia, mientras la transformada de Fourier utiliza ondas sinusoidales para realizar el análisis de una señal, la transformada Wavelet utiliza una serie de funciones llamadas Wavelet que significa ondícula u onda pequeña. Existen una gran variedad de familias o tipos distintos de funciones Wavelet, así este análisis tiene el inconveniente en que se tiene que definir a priori algunos parámetros como lo son: la función Wavelet a utilizar y el nivel de descomposición y que estos parámetros sean los que mejor se adapten y los que nos proporcionen la mejor información al momento de realizar la DWT en nuestras señales sEMG a analizar, puesto que para distintas funciones Wavelet se tendrá efectos distintos en los resultados de la descomposición.

Phinyomark et al. [37] realizó un estudio donde evalúa los resultados al utilizar siete funciones Wavelets distintas para la extracción de características en señales sEMG para la clasificación de patrones, dicha clasificación se basa en reconocer seis movimientos de la vida cotidiana del miembro superior, las Wavelets que fueron utilizadas en su estudio fueron: Daubechies de segundo y séptimo orden (db2, db7), la Wavelet Coiflet de cuarto y quinto orden (coif4, coif5), las wavelets Symlets y BioSplines de quinto orden respectivamente (sym5, bior5.5) y la ReverseBior de segundo orden (rbio2.2), obteniendo que la Wavelet Daubechies de séptimo orden y con un nivel de descomposición igual a cuatro arroja una mejor separabilidad de clases y esto hará que la precisión de la clasificación sea lo más alta posible.

Shanmuganathan et al. [38] plantea en seleccionar la función Wavelet identificando cual de ellas posee una mejor correlación con la señal de estudio, así para el análisis de señales sEMG para el reconocimiento de gestos plantean el uso de la Wavelet Daubechies de séptimo orden con 4 niveles de descomposición. Los parámetros seleccionados para llevar a cabo el análisis por medio de la DWT se basaron ampliamente en los estudios mencionados anteriormente, así de esta manera se definió utilizar la Wavelet Daubechies de séptimo orden, sin embargo el nivel de descomposición seleccionado fue de cinco niveles, un nivel más a lo que plantean los autores, esto con el fin de ver sus efectos al momento de la extracción de características así como en el rendimiento en la clasificación de los movimientos, además que las características de nuestras señales sEMG permiten llegar hasta este nivel de descomposición. En la figura 3.13 se observan los resultados de descomponer una señal sEMG en 5 niveles utilizando la Wavelet db7.

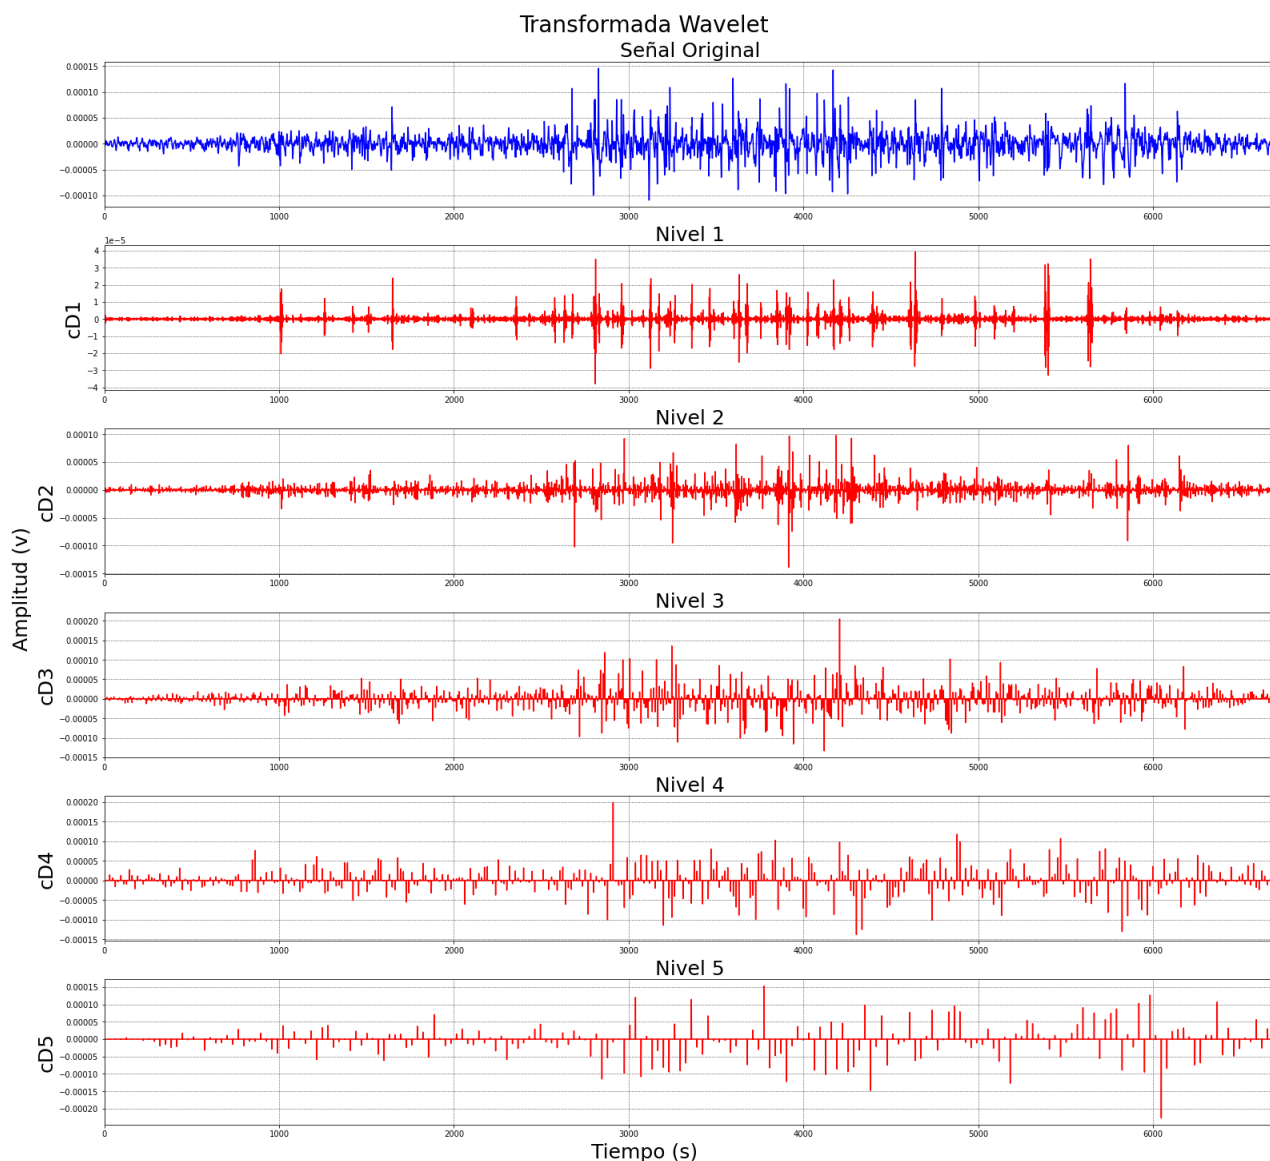


Figura 3.13: Descomposición de la señal sEMG en 5 niveles mediante la DWT utilizando la Wavelet db7.

### 3.4.2. Análisis por Descomposición de Modos Empíricos por Conjuntos

#### 3.4.2.1. Descomposición de modos empíricos

El método de descomposición de modos empíricos (EMD: *Empirical Mode Decomposition*) es ampliamente usado para tratar datos que provienen de procesos no estacionarios y no lineales, además que resulta ser intuitivo, directo y adaptativo. La descomposición se basa en la suposición de que cualquier señal o conjunto de datos consta de diferentes modos intrínsecos. Cada modo intrínseco representa un modo de oscilación simple que se encuentra dentro de los datos el cual tiene el mismo número de extremos (máximos y mínimos) y de cruces por cero, además la oscilación también debe ser simétrica respecto a la media local. Así este método genera cada uno de estos modos denominados como funciones de modo intrínseco (IMF: *Intrinsic Mode Function*), sin embargo la señal puede tener muchos modos de oscilación coexistentes, para que estos modos sean considerados como IMF estos tienen que cumplir con las siguientes condiciones:

- 1) El número de extremos (máximos y mínimos) y de cruces por cero debe de ser igual o diferir solamente en uno.
- 2) En cualquier punto, el valor de la media de la envolvente definida por los máximos locales y la envolvente definida por los mínimos locales debe de ser cero.

Una IMF representa un modo oscilatorio simple como contraparte de la función armónica simple, pero es mucho más general: en lugar de amplitud y frecuencia constantes, como el componente armónico simple, una IMF tiene una amplitud y frecuencia variables como funciones del tiempo [39, 40]. Para llevar a cabo la descomposición de una señal  $x[n]$  mediante la aplicación del método EMD para obtener sus  $k$  funciones de modo intrínseco ( $IMF_k$ ) se debe seguir la siguiente metodología [41, 42]:

1. Inicializar  $s[n] = x[n]$  como la señal de entrada.
2. Identificar todos los extremos (máximos y mínimos) para la señal  $s[n]$ .
3. Interpolar los máximos y mínimos de manera independiente para generar la envolvente superior correspondiente a los valores máximos  $e_{max}(n)$  y la inferior correspondiente a los valores mínimos  $e_{min}(n)$ .
4. Calcular la media de las dos envolventes:  $m[n] = \frac{e_{max}(n) + e_{min}(n)}{2}$ .
5. Extraer un modo de oscilación  $c[n]$ , restando la media a la señal  $s[n]$ :  $c[n] = s[n] - m[n]$
6. Verificar si  $c[n]$  cumple con las condiciones de una IMF:
  - a) Si no cumple  $c[n]$  pasa a ser la señal de entrada:  $s[n] = c[n]$  y repetir desde el paso número 2.
  - b) Si cumple, establecer  $c[n]$  como una IMF:  $IMF_k = c[n]$  y de la misma manera:  $r_k[n] = s[n] - c_k[n]$ , asignando ahora a la señal de entrada el valor de:  $r_k$ ;  $s[n] = r_k[n]$
7. Iterar el proceso hasta que el residuo final:  $r_k[n] = s[n] - c_k[n]$  sea una señal monótona.

Terminado el proceso de descomposición la señal original  $x[n]$  puede ser representada como:

$$x[n] = \sum_{i=1}^k IMF_i[n] + r[n] \quad (3.4)$$

La figura 3.14 muestra el diagrama de flujo para la EMD. Donde  $r_k[n]$  es el residuo final y es considerado como la tendencia de la señal y  $k$  es el número total de IMF. Cada una de las IMF contienen bandas de frecuencia que van de la alta a la baja frecuencia. Los componentes de frecuencia contenidos en cada banda son distintos y estos cambian con la variación de la señal  $x[n]$ . Aunque la EMD es un método ampliamente utilizado uno de sus principales inconvenientes que plantea es la aparición frecuente de “mezcla de modos” que se define como oscilaciones de escala o amplitud muy dispares en uno o mas modos así como oscilaciones muy similares que residen en diferentes modos. La mezcla de modos es a menudo una consecuencia de la intermitencia de la señal, además de que esta intermitencia puede ocasionar que la interpretación física de una IMF sea poco clara [40]. Para solucionar la mezcla de modos se propone la descomposición empírica de modos por conjuntos (EEMD: *Ensemble Empirical Mode Decomposition*) que es un método de análisis similar al EMD pero que ahora es asistido por ruido.

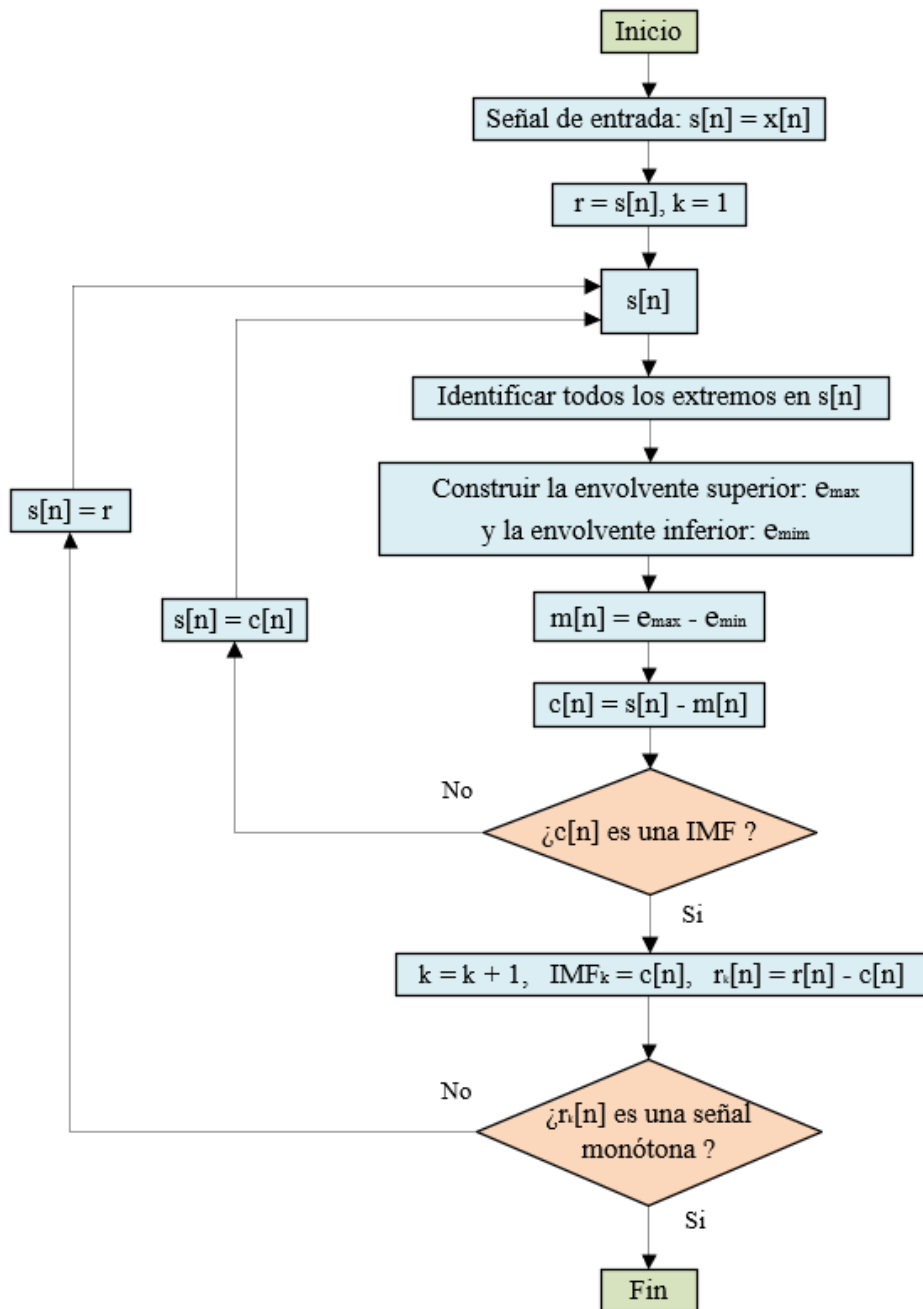


Figura 3.14: Diagrama de flujo para llevar a cabo la descomposición de modos empíricos (EMD).

### 3.4.2.2. Descomposición de Modos Empíricos por Conjuntos

La idea clave de la descomposición empírica de modos por conjuntos (EEMD: *Ensemble Empirical Mode Decomposition*) se basa en promediar los modos obtenidos por EMD aplicados a varias realizaciones de ruido blanco gaussiano añadido a la señal original y dado que el ruido añadido es diferente en cada realización, los IMF resultantes no muestran ninguna correlación con los IMF correspondientes de un ensayo a otro. Si el número de ensayos es adecuado, el ruido añadido puede eliminarse promediando el conjunto de los IMF obtenidos relacionados con los diferentes ensayos [43, 44]. Entonces el método EEMD define a los *modos verdaderos* como la

media de las IMF obtenidas con EMD sobre un conjunto de pruebas, cada una de las cuales consta de la señal más la adición de ruido blanco de amplitud finita [45]. En la figura 3.15 se observa la descomposición EEMD aplicada a una señal sEMG en la cual se obtuvieron 12 IMF. El algoritmo de EEMD se describe de la siguiente manera:

1. Generar  $x^i[n] = x[n] + w^i[n]$  donde  $w^i[n]$  ( $i = 1, \dots, I$ ) son realizaciones distintas para ruido blanco gaussiano.
2. Descomponer cada  $x^i[n]$  ( $i = 1, \dots, I$ ) mediante EMD obteniendo  $IMF_k^i[n]$  donde  $k = 1, \dots, K$  indican los modos.
3. Asignar  $\overline{IMF}_k$  como el k-ésimo modo de  $x[n]$ , obtenido al promediar los correspondientes  $IMF_k^{(i)}$ :  $\overline{IMF}_k[n] = \frac{1}{I} \sum_{i=1}^I IMF_k^i[n]$




Figura 3.15: Descomposición EEMD de una señal sEMG con sus 12  $IMF_k$ .

### 3.4.3. Análisis por Descomposición de Modo Variacional

Para efectuar la DWT se tienen que definir algunos parámetros a priori antes de llevar a cabo la descomposición, la EMD presenta unas desventajas como lo son: la alta sensibilidad al ruido y a la frecuencia de muestreo, para mitigar estos inconvenientes que presentan la DWT y la EMD el método de descomposición de modo variacional (VMD: *Variational Mode Decomposition*) es una descomposición adaptativa la cual descompone una señal de forma no recursiva en funciones o modos de banda limitada, Dragomiretskiy propuso este método como una generalización del filtro de Wiener a múltiples bandas adaptativas [46]. Así el objetivo de la VMD es el descomponer una señal de entrada  $f$  de valor real en un número discreto  $k$  de subseñales o funciones de modo variacional (VMF: *Variational Mode Function*) de banda limitada ( $u_k$ ) donde la superposición de estos modos constituyen la señal de entrada  $f$  tal como se muestra en la ecuación 3.5. Donde  $\bar{f}$  es la señal original,  $\Delta$  representa la señal de ruido y  $r_n$  es el residuo [11, 47, 48].

$$f = \bar{f} + \Delta = \sum_{k=1}^M u_k + r_n \quad (3.5)$$

Cada modo ( $u_k$ ) presenta propiedades de dispersión específicas mientras reproduce la entrada. La dispersión previa de cada modo se elige para que sea su ancho de banda en el dominio espectral. En otras palabras, se asume que cada modo es mayormente compacto alrededor de una pulsación central  $w_k$ , que se determinará junto con la descomposición, y su correspondiente condición de restricción es la ecuación 3.5. El correspondiente problema de la restricción variacional se muestra en la ecuación 3.6.

$$\min_{(u_k), (w_k)} \left\{ \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\} \quad (3.6)$$

$$\text{sujeto a: } \sum_k u_k = f$$

Haciendo uso de un término de penalización cuadrático y multiplicadores de Lagrange se puede hacer que el problema no esté restringido, obteniendo la siguiente ecuación:

$$L(\{u_k\}, \{w_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k \right\rangle \quad (3.7)$$

Donde  $\alpha$  es el factor de regularización,  $\lambda$  es el multiplicador Lagrange. Al introducir el método de multiplicación de dirección alterna (ADMM: *Alternate direction method of multipliers*) [49, 50], el resultado correspondiente se muestra en la siguiente ecuación:

$$u_k^{n+1} = \underset{u_k \in X}{\operatorname{argmin}} \left\{ \alpha \left\| \partial_t \left[ \left( \delta_t + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 + \left\| f(t) - \sum_i u_i(t) + \frac{\lambda(t)}{2} \right\|_2^2 \right\} \quad (3.8)$$



Haciendo uso del método de isometría de Parseval / Plancherel Fourier, este problema se puede resolver en el dominio espectral.

$$\hat{u}_k^{n+1}(w) = \frac{\hat{f}(w) - \sum_{i \neq k} \hat{u}_i(w) + \frac{\hat{\lambda}(w)}{2}}{1 + \alpha(w - w_k)^2} \quad (3.9)$$

$$w_k^{n+1} = \frac{\int_0^\infty w |\hat{u}_k(w)|^2 d(w)}{\int_0^\infty |\hat{u}_k(w)|^2 d(w)} \quad (3.10)$$

$$\hat{\lambda}^{n+1}(w) \leftarrow \hat{\lambda}^n(w) + \tau \left( \hat{f}(w) - \sum_k \hat{u}_k^{n+1}(w) \right) \quad (3.11)$$

Donde  $\tau$  es el parámetro de tolerancia al ruido. La condición de convergencia de la ecuación anterior es la siguiente.

$$\frac{\sum_k \|\hat{u}_k^{n+1} - u_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (3.12)$$

El VMD requiere un número determinado de modos, conocido como  $k$ . La principal diferencia entre cada modo es la frecuencia central. Para el desarrollo de esta investigación se propuso un número  $k = 5$  modos de descomposición, generando 5 funciones de modo variacional (VMF). Así para realizar la descomposición por este método a cada señal sEMG se sigue la siguiente metodología:

1. Inicializar  $\hat{u}_k^1$ ,  $\hat{w}_k^1$  y  $n$ .
2. Actualizar  $u_k$  y  $w_k$  de acuerdo con las ecuaciones 3.9 y 3.10.
3. Actualizar  $\lambda$  :  $\hat{\lambda}^{n+1}(w) \leftarrow \lambda^n(w) + \tau \left[ \hat{f}(w) - \sum_k \hat{u}_k^{n+1}(w) \right]$ .
4. Dada una precisión de discriminación  $\varepsilon > 0$  para la convergencia del paso anterior, si  $\frac{\sum_k \|\hat{u}_k^{n+1} - u_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon$  se detiene la iteración, en caso contrario se retorna al paso número 2.

Usando la metodología descrita anteriormente se obtienen los modos  $u_k$  los cuales son señales moduladas en AM-FM descritas por la siguiente ecuación:

$$u_k(t) = A_k(t) \cos(\phi_k(t)) \quad (3.13)$$

Donde  $\phi_k(t)$  es una función no decreciente  $\phi_k' \geq 0$ , la envolvente es no negativa  $A_k \geq 0$ , de la misma manera la envolvente  $A_k$  y la frecuencia instantánea  $w_k(t) := \phi_k'$  varía mucho más lento que la fase  $\phi_k(t)$ .

La VMD tiene un gran uso en la eliminación de ruido, diagnóstico de desordenes neuromusculares y en el análisis de señales electrocardiográficas, lo que hace que este método se pueda aplicar a las señales sEMG para el reconocimiento y clasificación de gestos o movimientos de la mano, y debido a las ventajas que este posee sobre la DWT y la EMD se podría comprobar si los resultados obtenidos son mejores que los proporcionados por los otros dos métodos. La figura 3.16 muestra cada una de las VMF al descomponer una señal sEMG, de igual forma se puede visualizar los espectros en frecuencia correspondientes a cada uno de los modos, en donde cada espectro está limitado en banda y posee un frecuencia central.

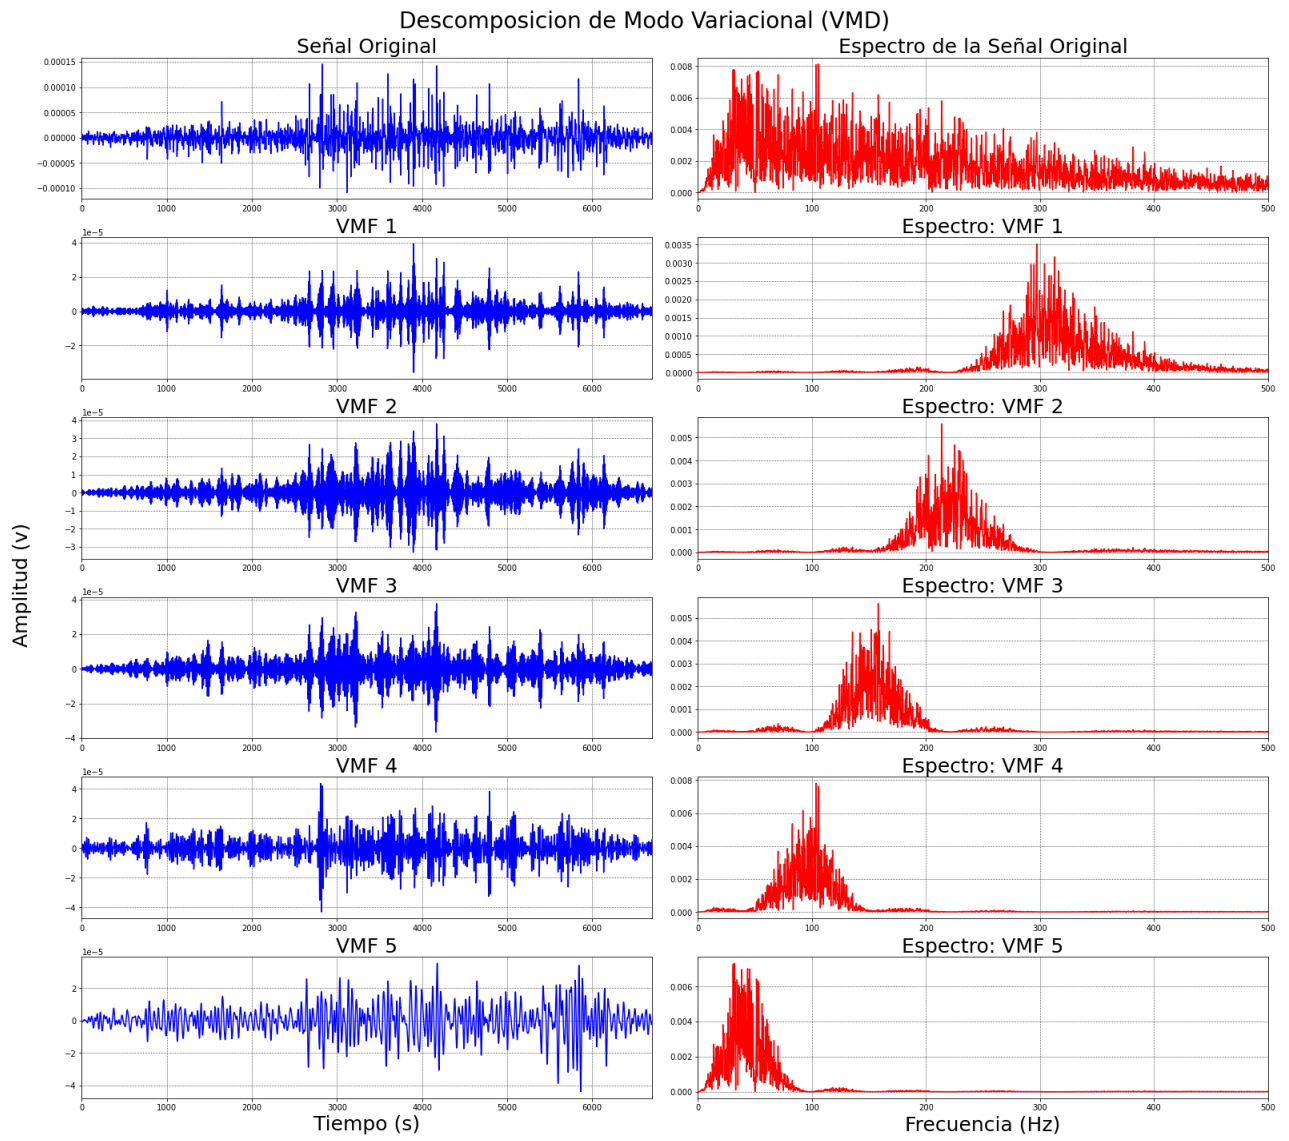


Figura 3.16: Descomposición de Modo Variacional con sus 5 VMF y sus respectivos espectros en frecuencia.

### 3.5. Ventaneo de las señales sEMG

El ventaneo es usado para dividir una señal en lapsos de tiempo o ventanas para calcular características sobre cada una de ellas. Debido a las limitaciones que implican las aplicaciones en tiempo real, la longitud de cada ventana debe ser igual o inferior a  $300\text{ ms}$  para que sumado al tiempo de procesamiento para la generación de comandos de control esto pueda ser considerado como una aplicación en tiempo real [51, 52]. Diversos autores plantean distintos tamaños de ventanas, [13, 14, 53, 54] sin embargo, todos coinciden en que la longitud de la ventana tiene que ser menor a  $300\text{ ms}$  para satisfacer el retraso aceptable que es proporcional al tiempo de reacción de la intención motora. Realizada la descomposición de las señales sEMG mediante los tres métodos descritos anteriormente se realiza el ventaneo de cada una de las descomposiciones o subseñales obtenidas.

Para este estudio cada subseñal es ventaneada por dos tamaños de ventana de manera independiente la primera de ellas de  $300\text{ ms}$  (600 muestras por ventana) como se muestra en la figura 3.17 y la segunda de  $500\text{ ms}$  (1000 muestras por ventana), el primero de estos valores se encuentra en el límite aceptable propuesto por estudios previos, sin embargo se decidió seleccionar estos dos tamaños de ventana ya que no tendrá por el momento una aplicación que pueda considerarse en tiempo real y de igual manera ver los efectos del tamaño de ventana al momento de llevar a cabo la clasificación de los movimientos de la mano, aunado a los análisis de descomposición y al número de sensores a utilizar el número de subseñales obtenidas por el ventaneo de la señal resultan ser demasiado grandes lo que ocasiona que se necesite más potencia de procesamiento y un alto costo computacional.

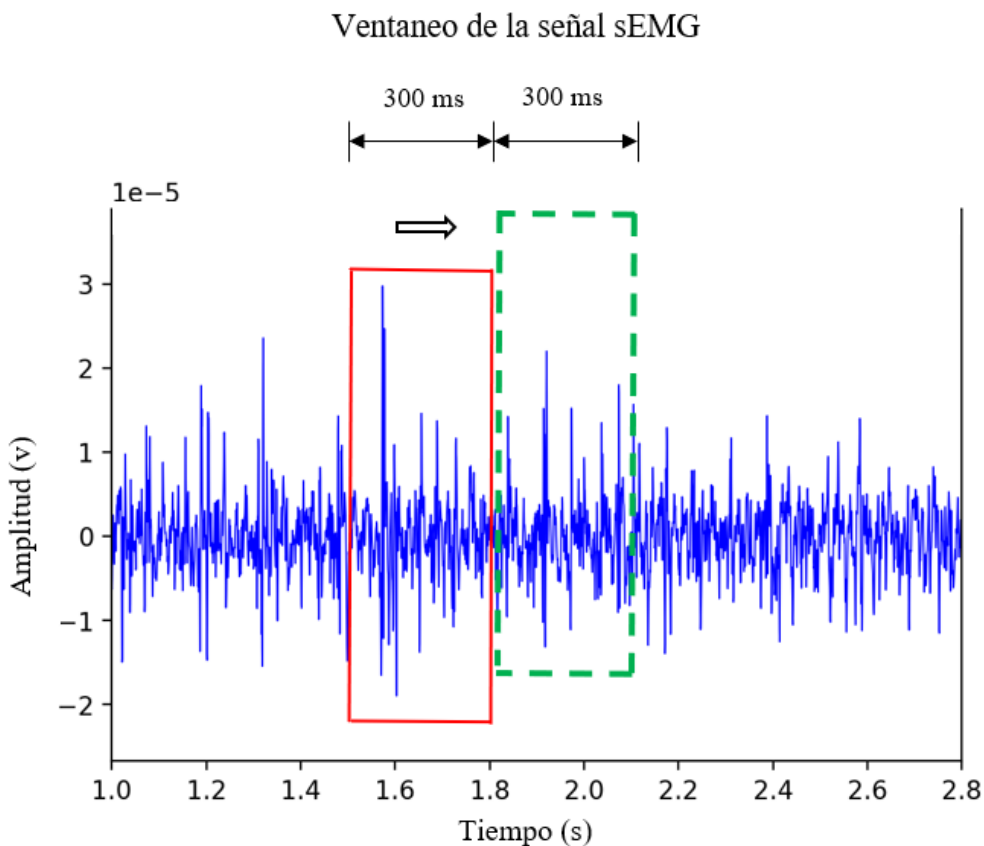


Figura 3.17: Ventaneo de las subseñales mediante ventanas de tiempo de  $300\text{ ms}$ .

### 3.6. Extracción de características

Las señales sEMG no son utilizadas como entradas a un clasificador puesto que el rendimiento que se obtendría sería muy deficiente, por ese motivo en el análisis de procesamiento de señales la extracción de características desempeña un papel fundamental para lograr una mejora en el rendimiento de la clasificación [55]. Así la extracción de características mapea las señales sEMG en un conjunto de características que representan, modelan y brindan información sobre el comportamiento de estas señales. En el análisis de señales EMG las características se pueden dividir en tres categorías o grupos, los cuales son:

1. Características en el dominio del tiempo (TD: *Time domain*).
2. Características en el dominio de la frecuencia (FD: *Frequency domain*).
3. Características en el dominio tiempo-frecuencia (TFD: *Time-Frequency domain*).

Las características en el dominio del tiempo son las más fáciles de implementar ya que estas no necesitan ningún tipo de transformación a la señal sEMG para ser calculadas, además tienen un amplio uso en aplicaciones en tiempo real y médicas debido a su bajo costo computacional, las características en el dominio de la frecuencia son propiedades estadísticas de la densidad espectral de potencia (PSD: *Power Spectral Density*) y se usan ampliamente en el estudio de la fatiga muscular y en el análisis de reclutamiento de unidades motoras [52, 56, 57]. La combinación de características del dominio tiempo junto a las de frecuencia definen las características tiempo-frecuencia las cuales proporcionan una información abundante de las señales en ambos dominios [58]. Una vez realizada la descomposición de las señales sEMG por los métodos de DWT, EEMD y VMD el siguiente objetivo es la extracción de características que permitan caracterizar las señales sEMG para cada movimiento y que estas permitan efectuar la clasificación de movimientos de la mano. Para cada método de descomposición se realizó la extracción de características para cada una de las ventanas y para cada nivel, IMF y VMF. En este estudio se utilizaron 6 características en el dominio del tiempo y 6 en el dominio de la frecuencia obteniendo de esta manera un vector de 12 características tiempo-frecuencia. A continuación se describen las características usadas en este estudio.

#### 3.6.1. Características en el dominio del tiempo

##### 3.6.1.1. Raíz media cuadrática: RMS

La raíz media cuadrática se modela como un proceso aleatorio gaussiano de amplitud modulada que se relaciona con la fuerza constante y la contracción no fatigante. También es similar al método de desviación estándar [57]. La definición matemática de la característica RMS se puede expresar como:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (3.14)$$

##### 3.6.1.2. Valor absoluto medio: VAM

Se obtiene promediando el valor absoluto de la señal EMG.

$$VAM = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (3.15)$$

### 3.6.1.3. Valor absoluto integrado: VAI

Se define como una suma de valores absolutos de la amplitud de la señal EMG, que se puede expresar como:

$$VAI = \sum_{i=1}^N |x_i| \quad (3.16)$$

### 3.6.1.4. Longitud de la forma de onda: LFO

La longitud de la forma de onda es una medida de la complejidad de la señal EMG. Se define como la longitud acumulada de la forma de onda EMG durante un segmento del tiempo. Se define como:

$$LFO = \sum_{i=1}^N |x_{i+1} - x_i| \quad (3.17)$$

### 3.6.1.5. Cruces por cero: CPC

Es el número de veces que los valores de amplitud de la señal EMG cruzan el nivel de cero, es decir, el número de veces donde el valor de la amplitud de la señal cambia de signo. Se tiene que definir un umbral en amplitud para evitar que un cruce por cero sea producido por fluctuaciones de voltaje bajo o ruidos de fondo. Existe un cruce por cero si:

$$g(i) = \{x_i > 0 \wedge x_{i+1} < 0\} \vee \{x_i < 0 \wedge x_{i+1} > 0\} \wedge |x_{i+1} - x_i| \geq \varepsilon.$$

Y el cálculo total para los cruces por cero se define como:

$$CPC = \sum_{i=1}^{N-1} g(i) \quad (3.18)$$

y  $\varepsilon$  es el umbral, el cual se definió con un valor de  $1 \times 10^{-5}$  ya que es el proporcionado por los fabricantes de los sensores que fueron utilizados para la adquisición de las señales sEMG. Si  $g(i)$  supera el umbral entonces se contabilizara un cruce por cero.

### 3.6.1.6. Cambios de pendiente en la señal: CPS

Es el cambio de signo en la pendiente de la señal, esta característica proporciona una medida de frecuencia. Dada tres muestras consecutivas  $x_{i-1}$ ,  $x_i$ ,  $x_{i+1}$  existe un cambio de pendiente si:

$$g(i) = \{x_i > x_{i-1} \wedge x_i > x_{i+1}\} \vee \{x_i < x_{i-1} \wedge x_i < x_{i+1}\} \wedge |x_{i+1} - x_i| \geq \varepsilon \vee |x_i - x_{i-1}| \geq \varepsilon$$
$$CPS = \sum_{i=1}^{N-1} g(i) \quad (3.19)$$

### 3.6.2. Características en el dominio de la frecuencia

La densidad espectral de potencia (PSD) se vuelve relevante al estudiar las señales en el dominio de la frecuencia, así la extracción de características en este dominio reflejan las propiedades estadísticas de la PSD. El uso de la transformada Hilbert es útil para calcular el contenido en frecuencia de una señal, así esta transformada se aplica a cada una de las descomposiciones para la extracción de características en este dominio. La transformada Hilbert se define como:

$$y(t) = H[x(t)] = \frac{1}{\pi} PV \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (3.20)$$

Donde PV denota el valor principal de Cauchy, a a partir de esta definición es posible expresar  $x(t)$  de forma fasorial con lo cual tenemos una señal analítica  $z(t)$ . Una señal analítica es una señal compleja que tiene una representación en el espectro de Fourier en un solo cuadrante, el cual corresponde a las frecuencias positivas. Al contrario, una señal de tiempo continuo con valor real tiene la propiedad de que su transformada de Fourier es simétrica compleja. Por tanto, la mitad de la frecuencia negativa del espectro de la señal contiene información redundante con respecto a la mitad de la frecuencia positiva. La señal analítica elimina esta redundancia espectral eliminando la mitad de frecuencia negativa de la transformada de Fourier de la señal. La señal de valor complejo resultante con espectro unilateral conserva toda la información contenida en la señal de valor real original y que son las adecuadas para conocer la frecuencia y la amplitud instantánea [59]. La señal analítica se puede expresar como:

$$z(t) = x(t) + jy(t) = a(t)e^{j\theta(t)} \quad (3.21)$$

donde:

$$a(t) = \sqrt{x(t)^2 + y(t)^2} \quad (3.22)$$

$$\theta(t) = \arctan\left(\frac{y(t)}{x(t)}\right) \quad (3.23)$$

$$\omega(t) = \frac{d\theta(t)}{dt} \quad (3.24)$$

Donde  $a(t)$  es la amplitud instantánea,  $\theta(t)$  es la fase instantánea y  $\omega(t)$  es la frecuencia instantánea. La frecuencia instantánea (FI) en ciclos/segundo puede ser calculada mediante la relación existente entre la frecuencia angular y la frecuencia,  $f = \omega/2\pi$  la cual se puede expresar como:

$$FI = \frac{1}{2\pi} \cdot \frac{d\theta}{dt} \quad (3.25)$$

De igual forma la densidad espectral de potencia (PSD) y la frecuencia media instantánea (MIF) están dadas por:

$$PSD = \left| \frac{1}{2\pi} \omega(t) \right|^2 \quad (3.26)$$

$$MIF = \frac{\sum_{j=1}^N \omega(j) a^2(j)}{\sum_{j=1}^N a^2(j)} \quad (3.27)$$

La transformada Hilbert es aplicada a cada uno de los modos obtenidos por los tres tipos de análisis con el fin de extraer seis características en frecuencia, a continuación se describe cada una de ellas.

### 3.6.2.1. Media de la primera derivada de la FI: MDF

La MDF proporciona información sobre la diferencia entre las frecuencias instantáneas adyacentes de la señal. Para encontrar la diferencia entre dos valores consecutivos de la FI, se calcula la primera derivada:

$$\delta_f = \left| \frac{d(FI)}{dt} \right| \quad (3.28)$$

El valor medio de la primera derivada de FI se puede representar como:

$$MDF = \frac{\sum_{j=1}^{N-1} \delta_f}{N-1} \quad (3.29)$$

### 3.6.2.2. Características de ancho de banda

El objetivo de estas características es proporcionar información sobre la difusión de frecuencia en las señales EMG debido a una modulación en amplitud (AM) o a una modulación en frecuencia (FM) o también a ambas modulaciones [60].

### 3.6.2.3. Ancho de banda modulado en amplitud: BAM

$$B_{AM} = \frac{\sum_{j=1}^N \frac{d}{dt} a(t)^2}{\sum_{j=1}^N PSD_j} \quad (3.30)$$

### 3.6.2.4. Ancho de banda modulado en frecuencia: BFM

$$B_{FM} = \frac{\sum_{j=1}^N (\omega(j) - MIF) a^2(j)}{\sum_{j=1}^N PSD_j} \quad (3.31)$$

### 3.6.2.5. Media de la frecuencia espectral: MNF

La frecuencia promedio que se calcula como la suma del producto del espectro de potencia de la señal EMG y la frecuencia dividida por la suma total del espectro en potencia. La cual puede ser calculada como:

$$MNF = \frac{\sum_{j=1}^N FI_j \cdot PSD_j}{\sum_{j=1}^N PSD_j} \quad (3.32)$$

donde:  $FI_j$  es la frecuencia del espectro en el intervalo de frecuencia  $j$ ,  $PSD_j$  es el espectro en potencia de la señal EMG en el intervalo de frecuencia  $j$  y  $N$  es la longitud del intervalo de frecuencia.

### 3.6.2.6. Momento espectral de la densidad espectral de potencia: SMPSD

Se define como el total del espectro en potencia y también se le conoce como primer momento espectral. Se expresa como:

$$SM_{PSD} = \sum_{j=1}^N j \cdot PSD_j \quad (3.33)$$

### 3.6.2.7. Frecuencia pico de la PSD: PKF

Es la frecuencia en la cual la potencia máxima espectral ocurre. Esta se define como:

$$PKF = \max(PSD_j), \quad j = 1, \dots, N \quad (3.34)$$

## 3.7. Redundancia entre sensores

En la figura 3.2 se muestra la ubicación de los electrodos para la adquisición de las señales sEMG. Los electrodos del 1 al 8 que están posicionados en el antebrazo presentan una gran redundancia debido al Cross Talk (superposición de señales sEMG) debido a que al tratarse de electromiografía de superficie resulta ser menos selectiva al registrar la señal EMG de un músculo en particular, obteniendo así una señal que contiene información electromiográfica del conjunto de músculos aledaños a la zona de donde se quiere obtener la señal sEMG de interés. Por esta razón se optó por utilizar un solo sensor del antebrazo, de esta manera para efectuar la clasificación y los análisis posteriores solo se tomará en consideración 5 sensores de los 12 que hay originalmente. Los registros de las señales sEMG de los sensores 7,9,10,11,12 serán utilizados.

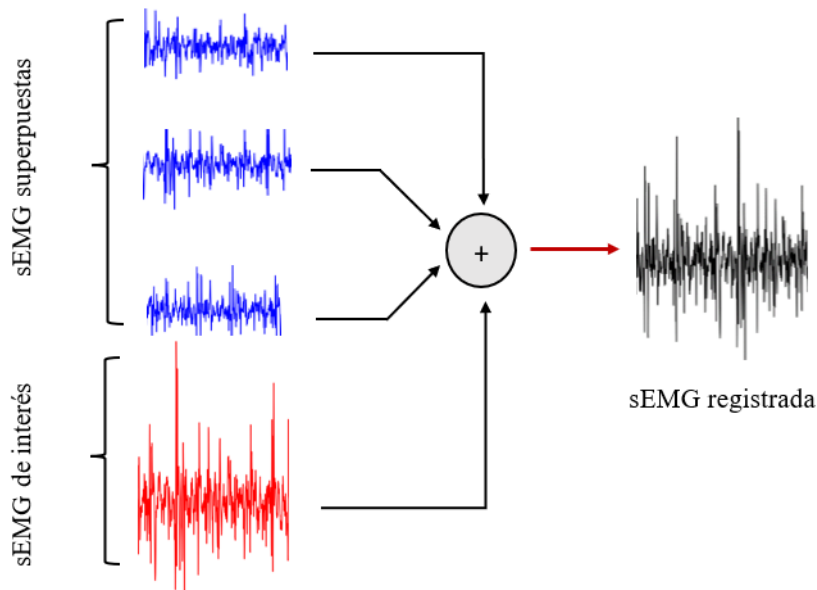


Figura 3.18: Superposición de señales EMG en la electromiografía de superficie.



### 3.8. Selección de características

La base de datos de señales sEMG para el reconocimiento de gestos de la mano se obtuvo de un total de 40 sujetos, los cuales ejecutaban 24 movimientos con 6 repeticiones por cada uno de los 5 sensores que fueron utilizados para adquirir las señales sEMG, de manera que existen un total de 5760 señales por sensor. Tomando en cuenta los métodos DWT, VMD y EEMD se tienen dos distintos niveles de descomposición, entonces el número de señales después de cada una de las descomposiciones para cada sensor será el número total de señales originales multiplicadas por los niveles o modos de descomposición tal como lo muestra la tabla 3.2.

Tabla 3.2: Niveles de descomposición y las subseñales generadas por sensor individual.

Método	Niveles \ Modos	Num.subseñales
DWT	5	28800
VMD	5	28800
EEMD	12	69120

Se tienen 5 niveles de descomposición para los dos primeros métodos y 12 niveles de descomposición para la EEMD, sin embargo para tener un estudio homogéneo solo los primeros 5 niveles de la descomposición EEMD fueron utilizados, resultando de esta manera un total de 28800 subseñales para cada uno de los métodos. Cada nivel y modo fue segmentado en ventanas, obteniendo un total de 16 ventanas para un tamaño de 300 *ms* y 10 ventanas para un tamaño de 500 *ms* por cada uno de los niveles o modos de descomposición, esto genera que se amplíe la información y con esto el número de señales para las cuales se obtendrán las características para llevar a cabo la clasificación. Se planteó también extraer características sin llevar a cabo el ventaneo esto con el propósito de analizar el comportamiento de la señal al efectuar una repetición completa de los movimientos y con esto comparar las ventajas y desventajas que puede tener el ventaneo de la señal. La tabla 3.3 muestra la cantidad de subseñales obtenidas para cada uno de los tamaños de ventanas.

Tabla 3.3: Número de subseñales después de efectuar el ventaneo de la señal.

Método	Niveles \ Modos	300 ms	500 ms	Sin ventaneo
DWT \ VMD \ EEMD	5	460800	288000	28800

Fueron 12 características utilizadas en este estudio así que el número total de características para cada método y para cada tamaño de ventana se obtendrá multiplicando el número de modos o niveles de descomposición por el número de características y por el número de sensores, obteniendo un total de 300 características. La tabla 3.4 muestra el número total de muestras generadas después de la extracción de características para cada método de descomposición.

Tabla 3.4: Número de muestras generadas para cada uno de los tamaños de ventana.

Tamaño de ventana	Num. muestras
300 ms	5529600
500 ms	3456000
Sin ventaneo	345000

La tabla anterior muestra un conjunto demasiado grande de características lo cual ocasiona que exista información redundante y esto puede ocasionar problemas al momento de entrenar un modelo de clasificación. Debido a la alta dimensionalidad que presentan los datos proporcionados por las características es necesario el uso de un proceso de selección de características que permita seleccionar cuales de ellas son las más relevantes y que pueden proporcionar información valiosa y de interés para llevar a cabo el proceso de clasificación, esto hace que disminuya la cantidad de datos y mejore el rendimiento del clasificador además de proporcionar una optimización en el procesamiento de los datos y de igual forma un mejor rendimiento computacional.

### 3.8.1. Clasificación de los movimientos por su taxonomía

En la figura 3.19 se pueden observar cada uno de los 23 movimientos de mano realizando tareas de la vida diaria y con objetos de uso común, con esto un modelado adecuado del agarre humano y de los movimientos de las manos es fundamental para la robótica, las prótesis, la fisiología y la rehabilitación. Las taxonomías de los agarres manuales que se han propuesto en la literatura científica hasta ahora se basan ampliamente en análisis y descripciones cualitativas rigurosas de los movimientos y, por lo tanto, generalmente no se justifican cuantitativamente. Este tipo de análisis son capaces de resaltar características intrínsecamente importantes de los movimientos de la mano, un análisis cualitativo es propenso a la subjetividad y no permite una confirmación o refutación demostrable ofrecida por métodos cuantitativos.

A simple vista podemos visualizar que muchos movimientos son semejantes y que posiblemente las señales sEMG no tengan gran diferencia entre los movimientos por lo cual Stival et al. [21] propone la primera taxonomía cuantitativa de agarres manuales basada en mediciones de datos biomédicos que fueron obtenidos en mediciones experimentales y análisis de datos estadísticos. Las variaciones relativas entre los ángulos de flexión de las articulaciones (medidos con un guante CyberGlove II) permiten una caracterización cuantitativa de la cinemática del movimiento de la mano y las señales sEMG permiten un análisis funcional de los músculos involucrados en cada agarre. La taxonomía está organizada en una estructura jerárquica y se basa en un procedimiento de extracción de características de señales que es común en la literatura de sEMG. Así la taxonomía cuantitativa general de los agarres manuales se basa en el estudio y análisis de dos taxonomías específicas las cuales son: sEMG y de datos cinemáticos.




Figura 3.19: Los 23 movimientos de la mano con objetos de uso común

Si bien la taxonomía cinemática puede ser más útil para la robótica, la taxonomía muscular puede ser más adecuada para aplicaciones en prótesis. Además, ambas taxonomías pueden tener aplicaciones en rehabilitación, fisiología y neurociencias. La taxonomía general tiene como objetivo proporcionar una solución intermedia a los diferentes campos y proporciona una representación cuantitativa completa de los agarres manuales, superando la subjetividad de las taxonomías cualitativas. En el estudio propuesto por Stival la taxonomía cuantitativa general sugiere una división en cinco grupos de agarres que recibieron el nombre en base a las propiedades específicas de cada grupo: 1) agarres cilíndricos, 2) agarres de anillo, 3) agarres distales, 4) agarres esféricos y 5) agarres de planos, con lo cual se puede hacer una comparación de esta taxonomía con taxonomías antes propuestas como la de Cutkosky la cual permite obtener una interpretación de los resultados.

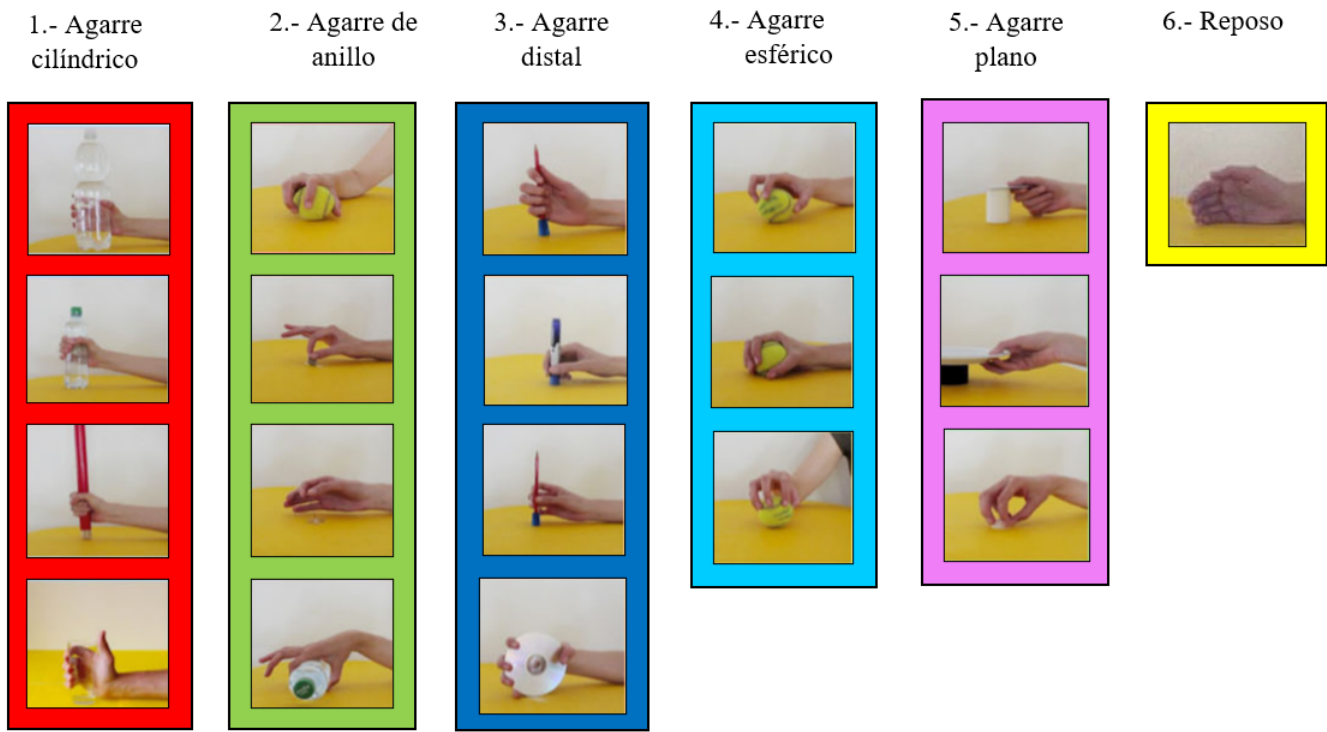


Figura 3.20: Movimientos de la mano clasificados en 6 grupos taxonómicos.

### 3.8.2. Métodos de selección de características

Los métodos de selección de características se pueden clasificar de varias formas según la relación con el método de aprendizaje, Estos son: los métodos de filtro, métodos de envoltura y los métodos integrados e híbridos. Los métodos de filtro seleccionan características basadas en una medida de rendimiento independientemente del algoritmo de clasificación. Solo después de encontrar las mejores características, los algoritmos de clasificación pueden usarlas. Los métodos de filtro pueden clasificar características individuales o evaluar subconjuntos completos de características, estos tienen la ventaja de que no son computacionalmente costosos y tienen una buena capacidad de generalización. Los métodos de envoltura consideran los subconjuntos de características por la calidad del rendimiento en un algoritmo de clasificación, el cual se toma como un evaluador. Este tipo de métodos son mucho más lentos que los métodos de filtro para encontrar subconjuntos suficientemente buenos porque dependen de las demandas del algoritmo de aprendizaje por lo cual es costoso computacionalmente.

Los métodos integrados realizan la selección de características durante la ejecución del algoritmo de clasificación. Por lo tanto, estos métodos están integrados en el algoritmo. Los métodos híbridos combinan las mejores propiedades de los métodos de filtro y de envoltura. En este tipo de método en primer lugar, se utiliza un método de filtro para reducir la dimensión del espacio de características, obteniendo posiblemente varios subconjuntos. Luego, se emplea el método de envoltura para encontrar el mejor subconjunto. Los métodos híbridos generalmente logran una alta precisión que es una característica del método de envoltura y una alta eficiencia característica del método de filtro [61, 62].

### 3.8.3. Prueba H de Kruskal-Wallis

El objetivo principal de la etapa de selección de características es el de mejorar y optimizar el sistema de clasificación de movimientos de la mano. Esto se realiza mediante la eliminación o el descarte de características que son catalogadas como irrelevantes para el modelo de clasificación y con esto ayudar a disminuir el tiempo computacional en el entrenamiento así como en el reconocimientos de gestos o movimientos de la mano. Para encontrar las características que presentan relevancia para el modelo clasificador se implementó una proceso estadístico utilizando una prueba no paramétrica llamada la prueba de Kruskal-Wallis la cual es adecuada cuando los datos no satisfacen condiciones de normalidad.

La prueba  $U$  de *Mann – Whitney* es una prueba no paramétrica para decidir si dos muestras provienen o no de una misma población. Una generalización de esta prueba para  $k$  muestras es la prueba  $H$  de Kruskal-Wallis o también conocida simplemente como *prueba H*. Esta prueba se puede describir como: suponiendo que tenemos  $k$  muestras, cuyos tamaños son  $N_1, N_2, \dots, N_k$  por lo que el tamaño total de las muestras estará dado por  $N = N_1 + N_2 + \dots + N_k$ . Además los datos de todas estas muestras se aglomeran y se ordenan de menor a mayor, y que las sumas de las posiciones de cada una de las  $k$  muestras son  $R_1, R_2, \dots, R_k$  respectivamente, entonces el estadístico se define como:

$$H = \frac{12}{N(N+1)} \sum_{j=1}^k \frac{R_j^2}{N_j} - 3(N+1) \quad (3.35)$$

Entonces se puede demostrar que la distribución muestral de  $H$  esta muy cercana a una distribución *ji cuadrada* con  $k - 1$  grados de libertad, siempre que  $N_1, N_2, \dots, N_k$ , sea por lo menos de tamaño 5 [63]. Para esta prueba se plantean dos hipótesis, las cuales suelen ser afirmaciones acerca de las distribuciones de probabilidad de las poblaciones.

- **Hipótesis Nula  $H_0$ :** Todas las muestras provienen de la misma población.
- **Hipótesis Alternativa  $H_1$ :** Al menos una muestra proviene de una población con una distribución distinta.

Posteriormente se utiliza la distribución de *ji-cuadrada* para estimar el valor  $p$  para esta prueba. Si la prueba de *Kruskal – Wallis* es significativa, es decir,  $p < 0.05$  implica que al menos dos grupos de entre los comparados son significativamente distintos, sin embargo esta prueba no indica cual de esos grupos presenta diferencia. Por lo cual hace que sea necesario comparar todas las posibles parejas de muestras, esto es realizar una corrección en el nivel de significancia para evitar cometer el error de tipo  $I$  el cual ocurre cuando rechazamos una hipótesis que debería ser aceptada.

### 3.8.4. Test de comparaciones múltiples de Bonferroni


La prueba  $H$  se basa en rechazar la hipótesis nula si la probabilidad de los datos observados en las hipótesis nula es baja, pero si se prueban múltiples hipótesis aumenta la probabilidad de rechazar incorrectamente una hipótesis nula (error de tipo  $I$ ). La corrección de Bonferroni compensa ese aumento al probar cada hipótesis individual en un nivel significativo de:  $\alpha/m$  donde  $\alpha$  es el nivel de significancia y  $m$  es el número de hipótesis. El test de Bonferroni dice que una diferencia por pares es significativa si:

$$\frac{|\bar{y}_i - \bar{y}_j|}{\sqrt{MSE \left( \frac{1}{n_i} + \frac{1}{n_j} \right)}} > t_{\alpha/2(k)} \quad (3.36)$$

donde  $t$  es el valor de la distribución  $t$  para  $\lambda$  grados de libertad y  $\alpha/2k$  de confianza,  $\bar{y}$  es la media y  $n$  es el tamaño de la muestra. Mediante este análisis estadístico se puede determinar la probabilidad de que dada una característica que fue extraída de una ventana de la señal sEMG para cada uno de los grupos taxonómicos no presente una diferencia estadística entre las distribuciones de los datos y con esto estableciendo una alta probabilidad de que esta característica no tenga la capacidad para discriminar entre las distintas clases pertenecientes a cada uno de los movimientos y de la misma manera puede establecer una alta probabilidad de que la característica sea apropiada para la clasificación de los movimientos. Para evitar un sobreajuste en los modelos predictivos al realizar la selección de las características adecuadas del conjunto de las señales sEMG ya descompuestas y segmentadas se utiliza el método de retención o de Holdout, el cual divide los datos en dos subconjuntos que no se superponen y estas dos partes se utilizan para entrenamiento y validación respectivamente. La parte que se utiliza para la validación es la parte resguardada. Se llama así porque se reserva esa parte para validar y se entrena el modelo utilizando la parte restante de los datos [64]. Así se toma el 70 % de los datos para el subconjunto de entrenamiento y el 30 % restante para la validación tomando la siguiente metodología y consideraciones.


1. Considerar que la base de datos esta constituida por señales sEMG de 40 sujetos, y para hacer más robusto este estudio este dato se toma como referencia, de igual manera se tomara la división por taxonomía de los movimientos teniendo así 6 clases a clasificar.
2. Del total de sujetos el 70 % de ellos con sus respectivas sEMG son seleccionadas para la fase de entrenamiento y el 30 % restante de los sujetos se tomará como validación. Teniendo de esta manera que los sujetos del 1 al 28 con sus sEMG son tomadas como datos para el entrenamiento y los sujetos del 29 al 40 son tomados como datos para la validación.
3. Se extrae una característica (tiempo/frecuencia) por cada una de las ventanas y se crean 6 vectores correspondientes a cada grupo taxonómico.
4. Se plantean las hipótesis nula y alternativa:
  - $H_0$  : La característica (tiempo/frecuencia) es la misma para cada clase de movimiento.
  - $H_1$  : La característica (tiempo/frecuencia) es distinta en al menos una clase de movimiento.
5. Se obtiene el valor  $p$  con la prueba de Kruskal-Wallis.
6. Si  $p < 0.05$  se usa el test de comparación múltiple de Bonferroni para determinar entre que clases de movimientos la característica (tiempo/frecuencia) tiene la capacidad discriminatoria.

Las visualizaciones gráficas de los datos son parte fundamental en el análisis estadístico de datos. Los gráficos o diagramas de caja son uno de los métodos gráficos más ampliamente utilizados para representar los estadísticos descriptivos de una muestra y visualizar comparaciones. Este diagrama muestra las principales propiedades que describen a un conjunto de datos: media (tendencia central), cuartiles 25 y 75 y los valores máximos y mínimos (extremos). Al poner en contraste las distribuciones de los datos pertenecientes a las clases de cada grupo taxonómico es posible visualizar las similitudes y las diferencias entre clases.



(a) Característica BAM del  $Nivel_3$  del sensor 11      (b) Característica SMPSD del  $Nivel_4$  del sensor 11

Figura 3.21: Diagrama de cajas de las distribuciones de datos de las características que no son útiles en la clasificación de los movimientos de la mano.



(a) Característica RMS del  $Nivel_1$  del sensor 11      (b) Característica MNF del  $Nivel_1$  del sensor 11

Figura 3.22: Diagrama de cajas para las distribuciones de datos de características que tienen la capacidad discriminatoria en la clasificación de los movimientos de la mano.

En las figura 3.21 se pueden observar 2 características del análisis por la Transformada Wavelet Discreta, la característica  $BAM$  (3.21a) fue extraída del  $Nivel_3$  de descomposición y

no muestra diferencias estadísticas entre las distintas clases de los grupos taxonómicos lo cual hace que sea una característica inútil al momento de realizar la clasificación de los movimientos, de igual forma la característica *SMP**SD* (3.21b) extraída del nivel 4 resulta no ser útil, para comprobar lo anterior podemos recurrir al *valor p* de cada una de estas características, los valores fueron:  $p = 0.0697$  y  $p = 0.6955$  respectivamente. En la figura 3.22 se observan las características que resultan ser apropiadas para discriminar entre las distintas clases de los grupos taxonómicos de movimientos. La primera de ellas es la característica *RMS* extraída del *Nivel 2* y la segunda es la *MNF* la cual también es extraída del mismo nivel de descomposición. Los valores de  $p$  para estas características fueron:  $p = 8.52E - 279$  y  $p = 4.2240E - 68$  con lo cual se rechaza la hipótesis nula de tener la misma distribución de información para las distintas clases.

Tabla 3.5: Valor  $p$  de las diferentes características tiempo-frecuencia en el análisis DWT.

Caract.	RMS	VAM	VAI	LFO	CPC	CPS	MDF	BAM	BFM	MNF	SMP	PKF
Nivel 1	0	0	1	0	0	0	0	2.72E-09	0	0	2.91E-09	0
Nivel 2	8.50E-279	0	1	0	0	0	0	4.56E-06	7.18E-278	4.22E-68	0.0273	6.99E-186
Nivel 3	4.39E-85	6.92E-45	1	0	4.32E-45	4.33E-45	0	0.0697	2.55E-76	5.42E-82	0.0019	1.35E-171
Nivel 4	0	0	1	0	0	0	0.0405	0.0408	0	3.29E-88	0.6955	0
Nivel 5	4.67E-297	2.51E-283	1	7.43E-254	1.07E-282	1.07E-282	0.9445	0.7749	1.70E-270	6.08E-83	0.7924	4.16E-239

Tabla 3.6: Valor  $p$  de las diferentes características tiempo-frecuencia en el análisis EEMD.

Caract.	RMS	VAM	VAI	LFO	CPC	CPS	MDF	BAM	BFM	MNF	SMP	PKF
IMF 1	2.28E-120	0	0	0	0	0	9.33E-238	0	8.42E-181	0	6.36E-11	1.19E-159
IMF 2	1.20E-178	8.50E-19	9.15E-130	1.61E-104	5.46E-72	5.46E-72	2.51E-94	9.58E-179	7.05E-120	1.53E-206	0	3.43E-165
IMF 3	4.92E-311	3.45E-302	1.15E-62	2.47E-52	3.83E-255	3.83E-255	5.66E-25	2.82E-111	1.87E-305	1.81E-16	7.21E-114	1.79E-260
IMF 4	6.27E-108	2.15E-242	2.18E-33	5.37E-26	6.16E-105	6.16E-105	6.95E-26	7.93E-34	4.11E-150	9.64E-40	4.64E-54	2.32E-96
IMF 5	2.52E-297	3.08E-143	1.12E-120	6.57E-110	2.10E-150	2.10E-150	3.45E-25	5.47E-18	1.24E-128	9.24E-21	5.51E-214	5.29E-135

Tabla 3.7: Valor  $p$  de las diferentes características tiempo-frecuencia en el análisis VMD.

Caract.	RMS	VAM	VAI	LFO	CPC	CPS	MDF	BAM	BFM	MNF	SMP	PKF
VMF 1	4.32E-122	0	0	0	1.59E-310	1.59E-310	3.21E-147	2.17E-90	4.78E-213	1.83E-18	0	4.31E-104
VMF 2	1.24E-55	7.16E-87	0	0	2.23E-27	2.23E-27	1.41E-242	1.19E-256	2.34E-17	1.76E-162	0	2.22E-93
VMF 3	6.84E-278	2.32E-54	2.99E-233	1.13E-262	8.81E-241	8.81E-241	0	1.15E-219	1.79E-144	1.65E-166	7.8E-162	0
VMF 4	3.48E-289	1.76E-169	1.67E-41	1.35E-45	3.92E-265	3.92E-265	1.94E-105	8.44E-69	5.30E-228	3.87E-93	4.81E-33	0
VMF 5	1.50E-50	5.95E-213	0	1.79E-114	5.25E-49	5.25E-49	1.12E-05	2.16E-07	2.34E-107	1.86E-41	0	2.12E-53

Las tablas 3.5, 3.6, 3.7 muestran los distintos valores de  $p$  para cada uno de los tres análisis. Estos valores son los correspondientes al sensor 11 (bíceps) y para cada uno de los niveles de descomposición. Tomando en consideración lo anterior y la manera en que se planteó el análisis, se tiene un número de 60 características por cada uno de los sensores, de esta manera por cada método de descomposición planteado (DWT, EEMD, VMD) se tendría un total de 300 características, de las cuales habrá un número variable de características que tendrán la cualidad de poder discriminar entre las distintas clases por cada uno de los sensores.

### 3.8.5. Reducción de características

Los datos obtenidos correspondientes a las características obtenidas tienen una alta dimensionalidad y para manejar más adecuadamente estos datos hace que sea necesario la implementación de métodos de reducción de características los cuales se basan en una transformación o combinación de los datos originales para la obtención de un nuevo subconjunto de información. Tradicionalmente, la reducción de características se realizaba utilizando técnicas lineales como el Análisis de Componentes Principales (PCA: *Principal Components Analysis*) y el Análisis del Discriminante Lineal (LDA: *Linear Discriminant Analysis*), estos métodos mapean un vector de características a una dimensión menor, es decir, la reducción de dimensionalidad es la transformación de datos de alta dimensión en una representación significativa de dimensionalidad reducida. Idealmente, la representación reducida debería tener una dimensionalidad que corresponda a la dimensionalidad intrínseca de las características. La dimensionalidad intrínseca de las características es el número mínimo de parámetros necesarios para tener en cuenta las propiedades que estas representan. La reducción de la dimensionalidad es importante, ya que mitiga la maldición de la dimensionalidad y otras propiedades no deseadas de los espacios de alta dimensión. Como resultado, la reducción de la dimensionalidad facilita, entre otras cosas, la clasificación, visualización así como los costos computacionales [65].

El análisis de componentes principales PCA es un mapeo lineal no supervisado basado en una búsqueda de vector propio y adecuado para datos gaussianos. PCA proporciona diferentes estrategias para reducir la dimensionalidad del espacio de características y conserva la cantidad máxima de varianza de los datos originales. El PCA se puede calcular utilizando diferentes algoritmos y las principales aplicaciones de PCA incluyen procesamiento de imágenes y voz, visualización, análisis de datos exploratorios y datos de sensores para aplicaciones en robótica. El objetivo de PCA es identificar un conjunto de características no correlacionadas conocidas como componentes principales (PC). El primer PC contiene la mayor cantidad de variación de los datos originales, mientras que el segundo PC representa la segunda variación más grande, y así sucesivamente [66].

LDA es el otro enfoque popular para la reducción de características, su objetivo principal es proyectar un conjunto de datos con un gran número de características en un espacio de menor dimensión con buena separabilidad de clases. El enfoque seguido por LDA es muy análogo al de PCA, además de maximizar la varianza de los datos LDA también maximiza la separación de múltiples clases [66, 67]. Sin embargo el método LDA presenta un problema al ser utilizado con datos submuestreados, es decir, cuando la dimensión del vector de características es mucho mayor que el tamaño de la muestra. Para esto hay una versión mejorada del método LDA el cual es el Discriminante Lineal no Correlacionado (ULDA: *Uncorrelated Linear Discriminant Analysis*) el cual impone el requisito adicional de que las características reducidas no estén correlacionadas estadísticamente entre sí de esta manera minimizando las redundancias [68].

### 3.8.6. Análisis del discriminante lineal no correlacionado (ULDA)

El análisis del discriminante lineal no correlacionado tiene como objetivo encontrar los vectores discriminantes óptimos que sean  $S - ortogonales$ . Específicamente supongamos que  $r$  vectores  $\phi_1, \phi_2, \dots, \phi_r$  son obtenidos, luego se encuentra el  $(r + 1) - esimo$  vector  $\phi_{r+1}$  para maximizar la función criterio de Fisher [69, 70].



$$f(\phi) = \frac{\phi^T S_b \phi}{\phi^T S_w \phi} \quad (3.37)$$

sujetos a las restricciones:  $\phi_{r+1}^T = 0$ , para  $i = 1, \dots, r$ . Donde  $S_b$  es la matriz de dispersión inter-clase y  $S_w$  es la matriz de dispersión intra-clase. El algoritmo en [69] encuentra  $\phi_i$  sucesivamente como sigue: El  $j$ -ésimo vector discriminante  $\phi_j$  de ULDA es el vector propio correspondiente al valor propio máximo del siguiente problema de autovalores generalizados:  $U_i S_b \phi_j = \lambda_j S_w \phi_j$ , donde:

$$U_1 = I_N \quad (3.38)$$

$$D_j = [\phi_1, \dots, \phi_{j-1}]^T \quad (j > 1) \quad (3.39)$$

$$U_j = I_N - S D_j^T (D_j S S_w^{-1} S D_j^T)^{-1} D_j S S_w^{-1} \quad (j > 1) \quad (3.40)$$

y  $I_N$  es la matriz identidad.

Supongamos que  $\{\phi_i\}_i = 1^d$  son los vectores discriminantes  $d$  óptimos para la fórmula ULDA anterior. Luego la matriz de datos original  $A$  se transfiere a  $Z = G^T A$ , donde  $G = \phi_1, \dots, \phi_d$ . El componente  $i$ -ésimo de  $Z$  es  $z_i = \phi_i^T A$  y la covarianza entre  $z_i$  y  $z_j$  es:

$$\begin{aligned} Cov(z_i, z_j) &= E(z_i - E z_i)(z_j - E z_j) \\ &= \phi_i^T \left\{ E(A - EA)(A - EA)^T \right\} \phi_j \\ &= \phi_i^T S \phi_j \end{aligned} \quad (3.41)$$

Por lo tanto, su coeficiente de correlación es:


$$Cor(z_i, z_j) = \frac{\phi_i^T S \phi_j}{\sqrt{\phi_i^T S \phi_i} \sqrt{\phi_j^T S \phi_j}} \quad (3.42)$$

Como los vectores discriminantes de ULDA son S-ortogonales, es decir,  $\phi_i^T S \phi_j = 0$ , para  $i \neq j$ , tenemos  $Cor(Z_i, Z_j) = 0$ , para  $i \neq j$ . Es decir, los vectores de características transformados por ULDA no están mutuamente correlacionados. Esta es una propiedad deseable para la reducción de características.

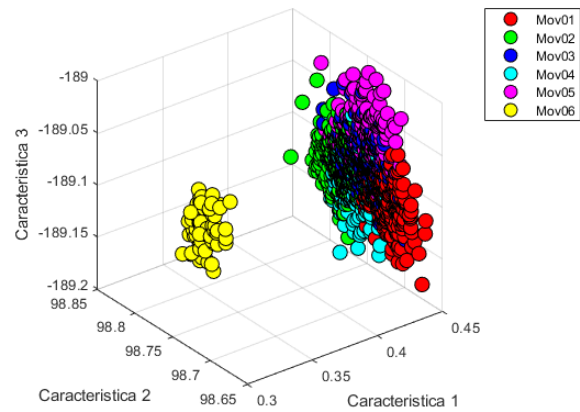
A partir de la implementación del método ULDA para realizar la reducción de la dimensión de las características se obtuvo la matriz  $G^{M \times l}$  de transformación utilizando el conjunto de entrenamiento el cual corresponde al 70 % de los datos. Posteriormente la matriz  $G$  es multiplicada por la matriz de información  $C_{caract.}^{N \times M}$  la cual esta compuesta por  $M$  características.

$$C_{ULDA} = C_{caract.}^{N \times M} \times G \quad (3.43)$$


Con la ecuación 3.43 obtenemos una matriz  $C_{ULDA}$  la cual es una nueva proyección de la matriz de datos original con solo  $l$  columnas, el valor de  $l$  esta dado por el número de clases menos uno ( $l = K - 1 = 5$ ) puesto que el número de clases originales son 6.




(a) DWT



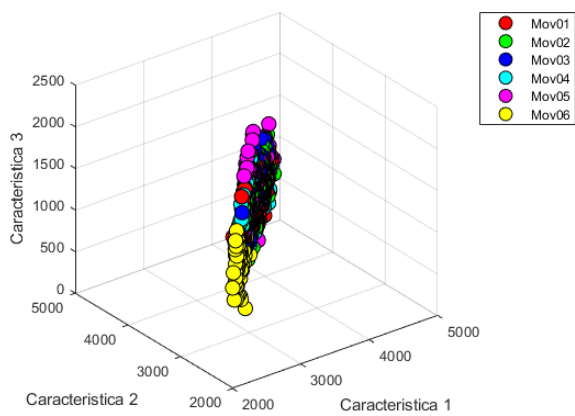
(b) DWT ULDA



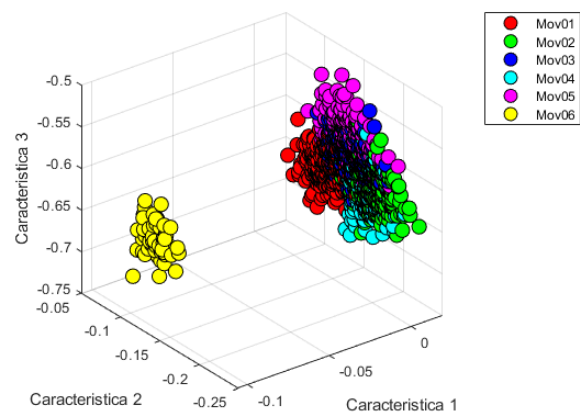
(c) EEMD



(d) EEMD ULDA




(e) VMD




(f) VMD ULDA


Figura 3.23: Gráfico de dispersión para ilustrar la reducción de la alta dimensionalidad del conjunto de características para cada método de descomposición sin la implementación del ventaneo.




(a) DWT




(b) DWT ULDA




(c) EEMD



(d) EEMD ULDA




(e) VMD




(f) VMD ULDA


Figura 3.24: Gráfico de dispersión para ilustrar la reducción de la alta dimensionalidad del conjunto de características para cada método de descomposición con la implementación del ventaneo con una ventana de 300 ms.




(a) DWT




(b) DWT ULDA




(c) EEMD



(d) EEMD ULDA




(e) VMD




(f) VMD ULDA


Figura 3.25: Gráfico de dispersión para ilustrar la reducción de la alta dimensionalidad del conjunto de características para cada método de descomposición con la implementación del ventaneo con un tamaño de ventana de 500 ms.




(a) Sin descomposición (SD)




(b) SD ULDA




(c) SD 300 ms



(d) SD 300 ms ULDA



(e) SD 500 ms



(f) SD 500 ms ULDA

Figura 3.26: Gráfico de dispersión para ilustrar la reducción de la alta dimensionalidad del conjunto de características para las señales sEMG sin llevar a cabo ningún método de descomposición de señales implementando el ventaneo de la señal para 300 ms y 500 ms.

### 3.8.6.1. Gráficos de dispersión

Las gráficas de dispersión anteriores ilustra el conjunto de información pertenecientes a las características originales así como el conjunto de datos después de pasar por el método de reducción de la dimensionalidad (ULDA). Se puede observar que a comparación con el conjunto de datos original donde toda la información se encuentra aglomerada y exhibiendo un gran traslape y redundancia de información en un solo grupo o cúmulo de datos, el método ULDA permite la mayor separación de clases puesto que de un solo cúmulo de información se pasa a la generación de 6 cúmulos visibles de información, donde se puede observar una mayor separabilidad entre las 6 clases de movimientos. Aunque aun exista traslape de información para las distintas clases esta resulta ser menor a comparación con los datos originales.

Utilizando la metodología planteada para el reconocimiento de gestos se realizan pruebas que permitan comparar entre la eficacia de los métodos de descomposición para la extracción de información relevante de una señal y ver las ventajas y desventajas que tiene sobre la implementación o no de estos métodos. Por lo cual las primeras tres pruebas consisten en la descomposición de la señal por cada uno de los métodos planteados por este estudio (DWT, EEMD, VMD), también se propone el análisis utilizando la señal completa (sin ventaneo) y para cada uno de los tamaños de ventana ( $300\text{ ms}$ ,  $500\text{ ms}$ ). La cuarta prueba consiste en utilizar la señal original sin haber utilizado ningún método de descomposición, implementándose de igual manera para la señal completa (sin ventaneo) y para cada uno de los tamaños de ventana.

En la figura 3.23 se observa la reducción de la dimensionalidad para cada uno de los métodos de descomposición pero sin efectuar ningún ventaneo de la señal, se puede visualizar que existe una buena separabilidad de clases y esto se puede explicar debido a que no existe el ventaneo de la señal permitiendo de esta manera tener la información completa desde el inicio hasta el final de la señal para cada uno de los movimientos. El movimiento de reposo presenta la mayor separabilidad en cada uno de los métodos de descomposición. La figuras 3.24 y 3.25 muestra la misma reducción de la dimensionalidad pero ahora con los datos obtenidos de cada método de descomposición pero con un tamaño de ventana de  $300\text{ ms}$  y  $500\text{ ms}$ , respectivamente. En estas figuras se puede visualizar también el efecto del tamaño de ventana, a medida que el tamaño de ventana pasa de  $300\text{ ms}$  a  $500\text{ ms}$  se observa una mayor separabilidad de clases debido a que se esta tomando una mayor cantidad de información de la señal sEMG, por consiguiente esto explicaría el motivo por el cual la implementación de la metodología sin efectuar el ventaneo de la señal presenta una mayor separabilidad de clases.

Finalmente la figura 3.26 muestra la reducción de la dimensionalidad pero aplicado al análisis sin ningún método de descomposición de señales, tanto para la señal completa así como para los dos tamaños de ventanas. Aquí también se puede observar el mismo efecto ocasionado al variar el tamaño de ventana y de igual forma se observa que presentan resultados muy semejantes en comparación con los métodos DWT, EEMD y VMD. Entonces para el reconocimiento de gestos para aplicaciones en tiempo real el realizar una metodología sin una descomposición de señales podría ser un buen enfoque para lograr el objetivo de reconocer o clasificar gestos de la manera más rápida y eficiente.

## Capítulo 4

# Algoritmos de clasificación

### 4.1. Reconocimientos de patrones

El reconocimiento de patrones (RP) se puede considerar como un proceso de clasificación que tiene como objetivo principal extraer patrones (características específicas) de un conjunto de datos y clasificarlos automáticamente en distintas categorías así que el RP puede caracterizarse como un proceso de reducción de información, mapeo de información o etiquetado de información, donde un patrón puede ser considerado como un conjunto de mediciones u observaciones [71]. Los métodos de RP pueden ser utilizados en distintos campos de estudio siendo uno de ellos el de la investigación biomédica, por lo tanto el RP puede ser aplicado al reconocimiento de gestos o movimientos de la mano.

Los enfoques del reconocimiento de patrones se subdividen en tres métodos principales: aprendizaje automático, estadístico y aprendizaje profundo, al implementar el reconocimiento de patrones al conjunto de información este podrá aprender de los datos ya que se incorpora algunos de los métodos antes mencionados. Poniendo énfasis en el aprendizaje automático este evolucionó a partir del estudio combinado del RP y la teoría del aprendizaje computacional y tiene como objetivo principal la implementación de aplicaciones que puedan aprender y también hacer predicciones con respecto a nuevos datos de manera autónoma.

Los algoritmos de aprendizaje automático hacen predicciones para un conjunto determinado de muestras y están divididos en dos grupos: aprendizaje supervisado y no supervisado. El aprendizaje no supervisado se basan en un enfoque de aprendizaje en el que las instancias se colocan automáticamente en grupos significativos en función de su similitud y el clasificador se diseña deduciendo patrones o grupos existentes en los conjuntos de datos de entrenamiento. Así este tipo de algoritmos son utilizados cuando las muestras no están etiquetadas. Los algoritmos de aprendizaje supervisado buscan patrones dentro de las etiquetas de valor asignadas a los puntos de datos. Estos algoritmos consisten en una variable de resultado a partir de la cual se debe predecir, es decir, un conjunto de predictores o variables independientes. Al usar este conjunto de variables, es posible generar una función que realice un mapeo de las entradas a las salidas deseadas. El proceso de entrenamiento continúa hasta que el modelo alcanza un nivel de precisión en los datos de entrenamiento. Algunos ejemplos de algoritmos de aprendizaje supervisado son: Maquinas de soporte vectorial (SVM: *Support Vector Machine*), bosques aleatorios (RF: *Random Forest*), árboles de decisión (DT: *Decision Tree*), redes neuronales, k-vecinos más cercanos (KNN: *K-Nearest Neighbors*), Naive Bayes, (NB) y redes neuronales artificiales (ANN: *Artificial Neural Network*).

## 4.2. Algoritmos de clasificación

Tres algoritmos de aprendizaje automatizado fueron usados en este estudio para el reconocimiento de los movimientos de la mano, estos fueron: k-vecinos más cercanos (KNN), máquinas de soporte vectorial (SVM) y árboles de decisión (DT). Estos fueron seleccionados para realizar una comparación entre estos algoritmos y evaluar su eficacia para la clasificación de movimientos permitiéndonos tener un punto de referencia para los trabajos o investigaciones futuras. A continuación se describe cada uno de ellos.

### 4.2.1. K-vecinos más cercanos

El algoritmo KNN es un método de clasificación no paramétrico simple pero efectivo para muchos casos. A diferencia de los métodos basados en modelos que primero aprenden a partir de las muestras de entrenamiento y luego predicen las muestras de prueba con el modelo aprendido, el algoritmo de k vecinos más cercanos es un modelo que no tiene una etapa de entrenamiento y realiza tareas de clasificación calculando primero la distancia entre la muestra de prueba y todas las muestras de entrenamiento para obtener sus vecinos más cercanos y luego realizando la clasificación (que asigna las muestras de prueba con etiquetas por la regla de la mayoría en las etiquetas de los vecinos más cercanos seleccionados), en la figura 4.1 se puede visualizar la clasificación de un registro o de una muestra, de esta manera para clasificar un registro de datos  $t$ , se recuperan sus  $k$  vecinos más cercanos, y esto forma una vecindad de  $t$  (datos o registros dentro del círculo con líneas punteadas). La votación por mayoría entre los registros de datos en el vecindario se usa generalmente para decidir la clasificación de  $t$  con o sin consideración de la ponderación basada en la distancia. Sin embargo, para aplicar KNN necesitamos elegir un valor apropiado para  $k$  (número de vecinos), y el éxito de la clasificación depende en gran medida de este valor. Esto hace que el método KNN esté sesgado por  $k$ . Hay muchas formas de elegir el valor de  $k$ , pero un simple método para elegir  $k$  es ejecutar el algoritmo muchas veces con diferentes valores de  $k$  y luego elegir o seleccionar el que tenga el mejor rendimiento [72, 73].

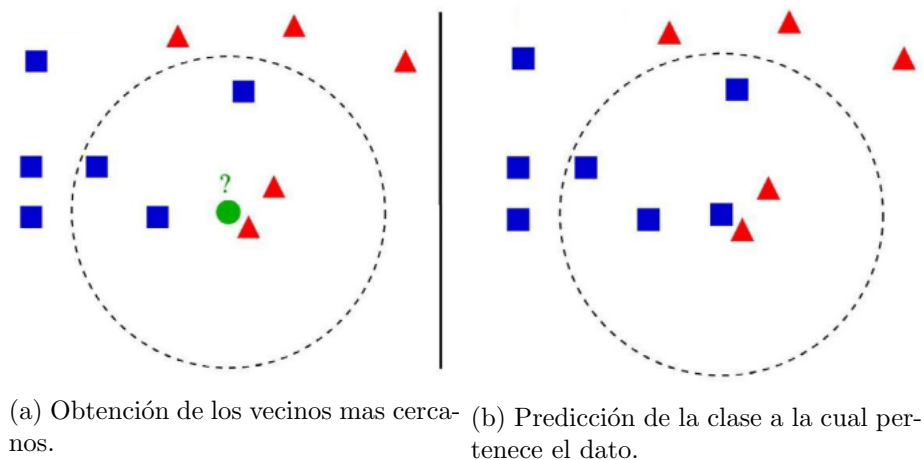


Figura 4.1: Clasificación de un dato por el método KNN.

El clasificador KNN se basa en medir las distancias entre los datos de prueba y cada uno de los datos de entrenamiento para decidir el resultado de la clasificación final. Para medir la distancia entre los puntos  $A$  y  $B$  en un espacio de características, en la literatura se han utilizado varias funciones de distancia, en las que la función de distancia euclidiana es la más utilizada. Sean  $A$



y  $B$  representados por los vectores de características  $A = (x_1, x_2, \dots, x_m)$  y  $B = (y_1, y_2, \dots, y_m)$ , donde  $m$  es la dimensionalidad del espacio de características. Para calcular la distancia entre  $A$  y  $B$ , generalmente se utiliza la métrica de la distancia euclidiana normalizada que esta dada por: [74].

$$dist(A, B) = \sqrt{\frac{\sum_i^m (x_i - y_i)^2}{m}} \quad (4.1)$$

#### 4.2.2. Máquinas de soporte vectorial

Las máquinas de soporte vectorial (SVM) se han convertido en un óptimo, versátil y popular modelo de aprendizaje automático capaz de realizar tareas que involucran clasificación, regresión y detección de datos anómalos o atípicos. Las SVM construye un hiperplano en un espacio multidimensional para separar las diferentes clases. Las SVM generan un hiperplano óptimo de forma iterativa, que se utiliza para minimizar un error. El objetivo principal de las SVM es encontrar un hiperplano marginal máximo que mejor divida el conjunto de datos en clases (figura 4.2). Donde en un espacio de  $p$  dimensiones un hiperplano se define como un subespacio plano y afín con dimensiones de  $p - 1$ . Por lo tanto considerando una clasificación binaria, es decir,  $p = 2$  el hiperplano es un subespacio de 1 dimensión, es decir, una recta.

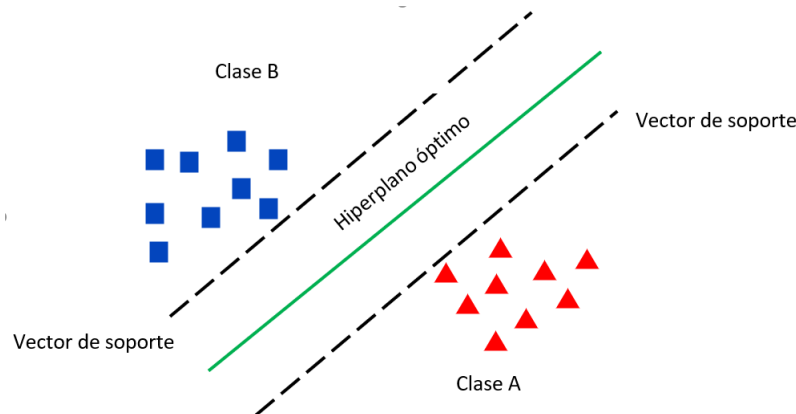


Figura 4.2: Clasificación por SVM para dos clases (clasificación binaria).

Las SVM se desarrollaron originalmente para separar dos clases, sin embargo, en muchos casos hay más de dos clases en el conjunto de datos, por lo que se han desarrollado varias estrategias para extender las SVM a fin de resolver problemas multiclase. Una estrategia principal consiste en dividir el problema multiclase en varios problemas de clases binarias y combinar las salidas de todos los clasificadores *sub binarios* para obtener la predicción final de la pertenencia de una muestra. Hay tres métodos principales basados en estos enfoques los cuales se denominan: uno contra todos (*one-against-all*), uno contra uno (*one-against-one*) y árbol DAG (DAG: *Directed Acyclic Graph*).

Uno contra todos (*one-against-all*) es el primer método reportado para extender las SVM binarias para resolver el problema multiclase. Dadas  $k$  clases, se construyen  $k$  modelos binarios de SVM, considerándose las muestras como parte de la clase o fuera de ella. La  $n$ -ésima ( $n = 1, \dots, k$ ) SVM se entrena con todas las muestras de la  $n$ -ésima clase etiquetada con  $+1$  y todas las demás muestras etiquetadas con  $-1$ . Por tanto, se pueden obtener funciones de decisión de  $k$  SVM para cada modelo. En el segundo enfoque “uno contra uno” dadas  $k$  clases, se construye  $k \cdot (k - 1) / 2$  clasificadores SVM binarios y cada uno entrena datos de dos clases. En

el árbol DAG SVM, la fase de entrenamiento es la misma que la de “*uno contra uno*” por lo cual se construyen  $k \cdot (k - 1)/2$  clasificadores SVM binarios. Pero al probar una muestra desconocida, utiliza un gráfico acíclico binario con  $k \cdot (k - 1)/2$  nodos internos. Cada nodo implica un  $i$ -ésimo modelo SVM binario “*uno contra uno*” para cada  $j$ -ésimas clases [75, 76].

### 4.2.3. Árboles de decisión

Un árbol de decisión (DT) es un modelo de clasificación y predicción más simples y fáciles de implementar, siendo utilizados en diversas disciplinas y cuyo objetivo principal es el aprendizaje inductivo y crear un modelo que prediga el valor de una variable objetivo mediante el aprendizaje de reglas de decisión simples inferidas de las características de los datos de entrada, así el árbol de decisión es una de las técnicas de clasificación en las que la clasificación se realiza mediante los criterios de división. El árbol de decisión es un diagrama de flujo como una estructura de árbol que clasifica las instancias clasificándolas según los valores de los atributos (características), de esta manera un árbol puede verse como una aproximación constante por partes, es decir, consiste en una segmentación del espacio predictor en regiones lógicas binarias. Comenzando de un nodo inicial del que se bifurca y se obtienen dos ramas cada una con un nuevo nodo, los cuales representan un posible resultado y cada uno de estos nuevos nodos conduce a nodos adicionales y estos nuevamente se ramifican de manera iterativa y finita hacia nuevos nodos que representan otras posibilidades obteniendo así las hojas de los árboles (nodos terminales) los cuales se utilizan para realizar la predicción de una muestra. Todos y cada uno de los nodos de un árbol de decisión representan un atributo en una instancia a clasificar. Todas las ramas representan un resultado de la prueba, cada nodo hoja tiene la etiqueta de la clase, así la instancia se clasifica en función de su valor de la característica. Los árboles de decisión tiene tres tipos de nodos: (1) nodos raíz, (2) nodos internos y (3) nodos terminales (*nodo hoja*) [77]. Existen exponencialmente muchos árboles de decisión que se pueden construir a partir de un conjunto dado de atributos. Si bien algunos de los árboles son más precisos que otros, encontrar el árbol óptimo es computacionalmente inviable debido al tamaño exponencial del espacio de búsqueda. Existen algoritmos que ayudan a su construcción los cuales son: ID3, C4.5 y CART.

#### Algoritmo ID3

El algoritmo ID3 fue propuesto en 1986 por Quinlan Ross. El concepto básico es hacer un árbol de decisiones utilizando el enfoque de arriba hacia abajo. ID3 utiliza la información obtenida para seleccionar la mejor característica, es decir, intenta identificar propiedades (o características) que diferencian una clase de otras. ID3 utiliza un cálculo llamado entropía condicional. Usando una característica para dividir los datos y calcular la entropía condicional, se puede determinar que características son más importantes. La característica más importante es la que da la entropía más baja. [78–80]

#### Algoritmo C4.5

ID3 tiene algunas limitaciones una de ellas es que es demasiado sensible a las características con un gran número de valores. Esta limitación debe superarse y esto se hace usando el algoritmo C4.5 que es una extensión del algoritmo ID3. El C4.5 se puede referir como un clasificador estadístico. Este algoritmo usa la tasa de ganancia para la selección de características y para construir el árbol de decisiones. Maneja características tanto continuas como discretas. El algoritmo C4.5 se usa ampliamente debido a su clasificación rápida y alta precisión.

## Algoritmo CART

El algoritmo CART (*Classification and Regression Trees*) fue desarrollado por Breiman et al [81]. CART es un algoritmo que en realidad funciona como un árbol binario donde cada nodo interno tiene exactamente dos bordes salientes que conducen a nodos terminales que pueden ser descritos por un conjunto de reglas específicas.

### 4.3. Métricas de clasificación

#### 4.3.1. Matriz de confusión

Una matriz de confusión (MC) esta asociada con un clasificador y muestra la clasificación predicha y real, donde  $k$  es el número de clases diferentes, por lo tanto la matriz de confusión tendrá unas dimensiones de  $k \times k$ . Durante la validación de un algoritmo de clasificación si una muestra ( $x$ ) es predicha correctamente, es decir,  $x = \hat{k}_i$ , entonces el elemento diagonal de la  $MC_{k,\hat{k}}$  perteneciente a la clase predicha correctamente se incrementa en 1. En caso contrario si la muestra es predicha de manera incorrecta entonces los elementos fuera de la diagonal se incrementara en 1. La figura 4.3 muestra una matriz de confusión para 2 clases.

		Clase predicha	
		P	N
Clase Real	P	Verdaderos Positivos (VP)	Falsos Negativos (FN)
	N	Falsos Positivos (FP)	Verdaderos Negativos (VN)

Figura 4.3: Matriz de confusión para 2 clases.

Donde:

- **VP:** Son los valores que el algoritmo clasifica como positivos y que realmente son positivos. (Verdaderos - positivos)
- **FP:** Valores que el algoritmo clasifica como positivo cuando realmente son negativos. (Falsos - positivos)
- **VN:** Son valores que el algoritmo clasifica como negativos y que realmente son negativos. (Verdaderos - negativos)
- **FN:** Valores que el algoritmo clasifica como negativos cuando realmente son positivos. (Falsos- negativos)

A partir de los valores obtenidos de la matriz de confusión, podemos obtener diferentes métricas que nos permitirán evaluar modelos de clasificación. A continuación se presentan algunas de las métricas más comunes.

### 4.3.2. Exactitud

Una vez que se han clasificado todas las muestras, la exactitud de la clasificación se basa en la relación entre el número de muestras clasificadas de manera correcta y el número total de muestras a clasificar (N), o de manera más simple, con qué frecuencia es correcto el clasificador. La exactitud se puede expresar como:

$$Exactitud = \frac{\sum_{i=1}^k MC_{k\hat{k}}}{N} \quad (4.2)$$

De igual manera se pueda expresar como:

$$Exactitud = \frac{VP + VN}{VP + VN + FP + FN} \quad (4.3)$$

Para este estudio se obtuvo la exactitud para cada uno de los modelos y para cada método de descomposición con el fin de tener una métrica que nos proporcione la probabilidad de que el resultado del clasificador prediga correctamente el tipo de movimiento a realizar.

### 4.3.3. Precisión

La precisión es la relación entre las predicciones correctas y el número total de predicciones correctas previstas, es decir, mide la precisión del clasificador al momento de predecir casos positivos. La precisión se puede calcular como:

$$Precisión = \frac{VP}{VP + FP} \quad (4.4)$$

### 4.3.4. Sensibilidad

La sensibilidad también es llamada en inglés recall, es la relación entre las predicciones positivas correctas y el número total de predicciones positivas. La sensibilidad nos indica la capacidad del clasificador para identificar un movimiento, por lo que se le llama también tasa o proporción de verdaderos positivos. Esta puede ser calculada como:

$$Sensibilidad = \frac{VP}{VP + FN} \quad (4.5)$$

### 4.3.5. Puntaje F1

Resume la precisión y sensibilidad en una sola métrica. Por ello es de gran utilidad cuando la distribución de las clases es desigual.

$$F1 = 2 \left( \frac{Sensibilidad \times Precisión}{Sensibilidad + Precisión} \right) \quad (4.6)$$

## Capítulo 5

# Resultados

En este capítulo se abordan los resultados obtenidos de las metodologías planteadas en este estudio para el reconocimiento de 6 movimientos de la mano, en donde cada movimiento hace referencia a un grupo taxonómico en particular. Para cada método de descomposición de señales (DWT, EEMD, VMD) se realizó la extracción de características mediante los siguientes tres esquemas:

1. Utilizando la señal completa para obtener información general de la señal sEMG para cada tipo de movimiento.
2. Ventaneando la señal con un tamaño de ventana de 300 ms que es el límite mínimo para que el reconocimiento de movimientos sea considerado como una aplicación en tiempo real.
3. Ventaneando la señal con un tamaño de ventana de 500 ms el cual proporciona la mitad de información de la señal sEMG, con el fin de ver los efectos de variar el tamaño de ventana.

Los tres esquemas anteriores tienen como finalidad el analizar las ventajas y desventajas que plantea el usar el ventaneo de señales para el reconocimiento de movimientos al igual que efectuar una comparación entre utilizar o no los métodos de descomposición de señales. También se llevo a cabo los mismos esquemas sin llevar a cabo ninguna descomposición (SD). De igual manera debido a la redundancia entre sensores se plantea un análisis para comprender si el número de sensores utilizados para la adquisición de señales sEMG tiene una repercusión en el reconocimiento de movimientos. Con lo anterior se entrenan tres modelos de aprendizaje automático los cuales son: k-vecinos más cercanos (KNN: *K-Nearest Neighbors*), máquinas de soporte vectorial (SVM: *Support Vector Machine*) y árboles de decisión (DT: *Decision Tree*).

A continuación se muestran las tablas que contienen los valores de la exactitud para cada uno de los modelos de aprendizaje automático con cada uno de los métodos de descomposición y para cada uno de los tamaños de ventana planteados, lo cual a su vez esta organizado por el número de sensores que se esta utilizando para llevar a cabo la clasificación.

## 5.1. Resultados utilizando 1 sensor

En las tablas 5.1, 5.2 y 5.3 muestran los valores de exactitud para cada método de descomposición y para cada esquema planteado (sin ventaneo, ventana: 300 ms, ventana de 500 ms). Se planteó el uso de un solo sensor para reducir al mínimo la redundancia entre sensores y poder comparar los resultados con el uso de 5 y 3 sensores. El sensor seleccionado fue el correspondiente al antebrazo ya que en esta parte del miembro superior presenta la mayor amplitud de la señal sEMG para cada movimiento. Se puede observar que los valores de exactitud obtenidos en esta prueba resultan ser mucho menores que los otros dos planteamientos con 5 y 3 sensores. Los mejores valores para la exactitud se obtienen al no hacer la reducción de la dimensionalidad y sin usar el ventaneo de la señal, siendo la descomposición EEMD la que presenta mejor resultado con un 40.49 % y utilizando el algoritmo de clasificación de máquinas de soporte vectorial.

Tabla 5.1: Valores de exactitud para el algoritmo de DT utilizando 1 sensor sEMG.

KNN	Sin Ventaneo		300 ms		500 ms	
	CarC	ULDA	CarC	ULDA	CarC	ULDA
DWT	36.47 %	22.95 %	30.03 %	29.56 %	30.19 %	30.03 %
VMD	33.84 %	15.13 %	29.48 %	25.79 %	30.43 %	27.44 %
EEMD	37.13 %	15.71 %	30.56 %	31.12 %	30.92 %	32.90 %
SD	33.18 %	30.48 %	29.46 %	19.07 %	29.64 %	19.02 %

Tabla 5.2: Valores de exactitud para el algoritmo de SVM utilizando 1 sensor sEMG.

SVM	Sin Ventaneo		300 ms		500 ms	
	CarC	ULDA	CarC	ULDA	CarC	ULDA
DWT	38.01 %	23.97 %	31.07 %	30.65 %	31.87 %	31.02 %
VMD	39.03 %	14.54 %	30.93 %	25.49 %	31.59 %	27.79 %
EEMD	40.49 %	16.30 %	32.86 %	32.74 %	33.22 %	34.04 %
SD	38.66 %	28.36 %	30.39 %	17.57 %	30.75 %	16.34 %

Tabla 5.3: Valores de exactitud para el algoritmo de DT utilizando 1 sensor sEMG.

DT	Sin Ventaneo		300 ms		500 ms	
	CarC	ULDA	CarC	ULDA	CarC	ULDA
DWT	31.79 %	21.05 %	29.84 %	29.12 %	29.29 %	28.94 %
VMD	33.11 %	14.54 %	29.42 %	29.24 %	29.77 %	28.04 %
EEMD	34.42 %	19.51 %	27.03 %	31.88 %	24.34 %	32.14 %
SD	25.36 %	28.80 %	31.02 %	18.51 %	31.08 %	18.60 %

## 5.2. Resultados utilizando 3 sensores

En las tablas 5.4, 5.5 y 5.6 muestran los valores de exactitud para cada método de descomposición y para cada esquema planteado (sin ventaneo, ventana: 300 ms, ventana de 500 ms). Para comparar el efecto que puede ocasionar el uso de cierto número de sensores para la adquisición de las señales sEMG y para efectuar el reconocimiento de gestos se realiza la prueba solo utilizando tres sensores esto con el fin de disminuir los efectos de la redundancia de información que estos generan a causa de que es una señal EMG de superficie. Los sensores seleccionados fueron el sensor correspondiente al antebrazo, al músculo flexor y al músculo extensor. Estos tres sensores fueron seleccionados ya que son fundamentales para efectuar diversos tipos de agarre ya que la mayor amplitud de las señales sEMG se encuentra en estos músculos y además que son los responsables de la flexión y extensión de la mano así como de los dedos. Se puede observar que para el algoritmo SVM y utilizando la reducción de la dimensionalidad y la señal sin ningún tipo de ventaneo se tiene los mejores resultados para los métodos de descomposición DWT y VMD con un valor de 45.02 % y 41.37 % respectivamente.

Tabla 5.4: Valores de exactitud para el algoritmo de KNN utilizando 3 sensores sEMG.

KNN	Sin Ventaneo		300 ms		500 ms	
	CarC	ULDA	CarC	ULDA	CarC	ULDA
DWT	36.84 %	45.46 %	31.96 %	17.00 %	32.51 %	16.22 %
VMD	35.89 %	41.44 %	31.94 %	28.77 %	32.45 %	27.90 %
EEMD	36.76 %	27.04 %	32.36 %	32.09 %	32.95 %	32.25 %
SD	36.33 %	27.92 %	32.60 %	20.28 %	33.31 %	20.86 %

Tabla 5.5: Valores de exactitud para el algoritmo de SVM utilizando 3 sensores sEMG.

SVM	Sin Ventaneo		300 ms		500 ms	
	CarC	ULDA	CarC	ULDA	CarC	ULDA
DWT	41.37 %	45.02 %	35.76 %	15.08 %	36.45 %	14.64 %
VMD	42.76 %	41.37 %	34.78 %	28.29 %	35.96 %	27.98 %
EEMD	42.69 %	29.31 %	35.97 %	32.07 %	37.33 %	32.41 %
SD	41.30 %	27.33 %	34.89 %	19.24 %	35.59 %	19.92 %

Tabla 5.6: Valores de exactitud para el algoritmo de DT utilizando 3 sensores sEMG.

DT	Sin Ventaneo		300 ms		500 ms	
	CarC	ULDA	CarC	ULDA	CarC	ULDA
DWT	33.04 %	41.59 %	28.81 %	17.02 %	27.72 %	19.51 %
VMD	33.69 %	42.47 %	30.29 %	28.59 %	31.69 %	30.57 %
EEMD	34.57 %	22.14 %	29.42 %	32.96 %	25.63 %	29.60 %
SD	41.81 %	24.48 %	32.84 %	19.24 %	32.78 %	16.33 %

### 5.3. Resultados utilizando 5 sensores

En las tablas 5.7, 5.8 y 5.9 muestran los resultados de la exactitud de cada uno de los modelos de aprendizaje automático (KNN, SVM y DT) para cada uno de los tres esquemas planteados anteriormente. Las tablas también muestran la exactitud en la clasificación al utilizar el método ULDA para la reducción de la dimensionalidad de las características y la exactitud al no utilizar este método. Se puede observar que con el algoritmo KNN se tiene la mayor exactitud en el reconocimiento de los movimientos con un valor del 54.67% con el método de descomposición VMD y utilizando la reducción de la dimensionalidad (ULDA). De igual manera se tienen resultados semejantes con la descomposición VMD para los otros dos algoritmos de clasificación (SVM, DT) obteniendo 54.16% y 53.72% de exactitud respectivamente. Así los mejores resultados se obtuvieron utilizando la señal completa, es decir, sin efectuar ningún ventaneo de la señal. Al realizar el ventaneo de la señal la exactitud tiende a ser menor ya que se está tomando lapsos de tiempo de la señal que no logran describir completamente el comportamiento de la señal sEMG para cada tipo de movimiento.

Tabla 5.7: Valores de exactitud para el algoritmo de KNN utilizando 5 sensores sEMG.

KNN	Sin Ventaneo		300 ms		500 ms	
	CarC	ULDA	CarC	ULDA	CarC	ULDA
DWT	1.01 %	44.00 %	36.07 %	34.88 %	37.58 %	31.53 %
VMD	40.20 %	54.67 %	35.44 %	38.71 %	36.11 %	34.15 %
EEMD	6.57 %	42.32 %	36.86 %	12.23 %	37.44 %	29.51 %
SD	22.14 %	45.24 %	38.83 %	41.47 %	39.21 %	42.07 %

Tabla 5.8: Valores de exactitud para el algoritmo de SVM utilizando 5 sensores sEMG.

SVM	Sin Ventaneo		300 ms		500 ms	
	CarC	ULDA	CarC	ULDA	CarC	ULDA
DWT	1.16 %	46.19 %	36.22 %	42.28 %	32.19 %	43.34 %
VMD	46.63 %	54.16 %	39.09 %	40.13 %	34.14 %	40.94 %
EEMD	7.20 %	42.32 %	12.04 %	41.81 %	30.12 %	43.09 %
SD	21.71 %	48.68 %	43.08 %	40.68 %	44.01 %	41.68 %

Tabla 5.9: Valores de exactitud para el algoritmo de DT utilizando 5 sensores sEMG.

DT	Sin Ventaneo		300 ms		500 ms	
	CarC	ULDA	CarC	ULDA	CarC	ULDA
DWT	2.63 %	40.71 %	11.85 %	35.98 %	35.04 %	33.85 %
VMD	37.64 %	53.72 %	38.48 %	35.59 %	31.81 %	32.71 %
EEMD	3.21 %	38.01 %	11.85 %	34.35 %	34.34 %	27.32 %
SD	18.56 %	45.83 %	40.47 %	36.71 %	37.42 %	41.72 %



## 5.4. Matrices de confusión

A continuación se muestran las matrices de confusión y sus métricas de la clasificación efectuada por los 5 sensores para el esquema “sin ventaneo” puesto que fue en donde se obtuvo una mejor clasificación de los movimientos de la mano. Dichas matrices nos permiten visualizar las predicciones correctas e incorrectas para el algoritmo KNN para cada método de descomposición y para la señal original (sin realizar un método de descomposición).

### 5.4.1. Transformada Wavelet discreta




Figura 5.1: Matriz de confusión para la DWT

Métrica	Valor
Exactitud	0.4432
Precisión	0.4538
Sensibilidad	0.6581
F1	0.5361

Tabla 5.10: Métricas generales para la clasificación DWT

### 5.4.2. Descomposición de modo variacional

A continuación se muestra la matriz de confusión y las métricas de clasificación para el método VMD que es donde se obtuvieron los mejores resultados en la exactitud con un valor de 54.67% para el reconocimiento de los 6 movimientos taxonómicos.




Figura 5.2: Matriz de confusión para la VMD

Métrica	Valor
Exactitud	0.5467
Precisión	0.5947
Sensibilidad	0.6658
F1	0.6282

Tabla 5.11: Métricas generales para la clasificación VMD

### 5.4.3. Descomposición de modos empíricos por conjuntos

A continuación se muestra la matriz de confusión y las métricas de clasificación para el método EEMD que es donde se obtuvieron los menores resultados en la exactitud en comparación con los métodos de descomposición obteniendo un valor de 42.32% para el reconocimiento de los 6 movimientos taxonómicos.




Figura 5.3: Matriz de confusión para la EEMD

Métrica	Valor
Exactitud	0.4232
Precisión	0.4420
Sensibilidad	0.6117
F1	0.5132

Tabla 5.12: Métricas generales para la clasificación EEMD

#### 5.4.4. Señal original: Sin descomposición

A continuación se muestra la matriz de confusión y las métricas de clasificación para la señal original, es decir, sin ser sometida a ningún método de descomposición.




Figura 5.4: Matriz de confusión para la señal original (sin descomposición)

Métrica	Valor
Exactitud	0.4524
Precisión	0.4535
Sensibilidad	0.6712
F1	0.5418

Tabla 5.13: Métricas generales para la clasificación de la señal original

Como se puede observar se lograron valores en exactitud por debajo del 60% para cada uno de los enfoques planteados, lo cual puede ser explicado por la naturaleza de las señales sEMG así como de la metodología de adquisición de estas señales, lo cual podría afectar la clasificación de los movimientos de la mano. El realizar el ventaneo de la señal también muestra tener efectos significativos en la clasificación de los movimientos puesto que al tomar lapsos de la señal estos no representan el comportamiento general de un movimiento en particular ya que un movimiento tiene un comportamiento distinto al inicio y final de la contracción para la ejecución de un movimiento.

## Capítulo 6

# Conclusiones

El estudio de las señales EMG para aplicaciones enfocadas en el reconocimiento de gestos o movimientos de la mano para ser utilizados en el control de prótesis de mano plantea un reto que va desde la metodología para la adquisición de las señales EMG hasta el reconocimiento de los patrones o características que permitan identificar diversos tipos de movimiento. Para este tipo de aplicaciones las señales EMG de superficie desempeñan la mejor opción para el desarrollo e implementación de este tipo de estudios puesto que su adquisición es de manera sencilla y no invasiva para las personas. Sin embargo este tipo de señales tienen la desventaja de ser muy complejas y no aportan una alta definición al momento de evaluar un músculo en particular y esto se debe principalmente a que existe actividad electromiográfica de músculos vecinos que están cerca a la zona de donde se está obteniendo las señales, por lo tanto se tendría una mezcla o superposición de señales sEMG.

En esta tesis se plantea el uso de tres métodos de descomposición de señales con el fin de extraer información multiresolución de cada señal además de plantear un ventaneo de la señal con lo cual se puede estudiar su implementación en tiempo real ya que es el objetivo principal en las aplicaciones enfocadas en prótesis de mano. El objetivo de este estudio es el reconocer diversos movimientos ejecutándose con objetos e instrumentos de la vida cotidiana, la base de datos utilizada para desarrollar este reconocimiento de gestos contiene 24 movimientos que son comunes, sin embargo, el clasificar cada uno de ellos de manera independiente resulta ser muy complejo ya que existen movimientos que son demasiados semejantes entre ellos. De esta manera el sistema propuesto no será factible para reconocer cada uno de estos movimientos, lo cual planteó que para realizar la clasificación de los movimientos estos fueran agrupados basándose en estudios de taxonomía para agarres manuales, lo cual ayuda a mejorar el reconocimiento de movimientos basándose en sus características y funciones como agarre manual.

En base a estudios ya realizados sobre la biomecánica de la mano así como de las diversas taxonomías, los movimientos son clasificados en 6 grupos taxonómicos los cuales describen de manera general cada uno de los movimientos sin importar que acción u objeto se este manipulando. De igual forma se observó que no existe una relación o mapeo directo del dominio neuromuscular y la taxonomía de los movimientos, es decir, las señales sEMG generadas para la activación y ejecución de un determinado movimiento no se relacionan directamente con la biomecánica del movimiento, así las señales generadas para cada movimiento resultan tener gran similitud, lo que ocasiona que no se pueda distinguir entre cada uno de los movimientos a ejecutar.

La descomposición de la señal por medio de los métodos DWT, VMD y EEMD nos permiten extraer información relevante que se encuentra dentro de la señal. Esto plantea que al momento de realizar la clasificación de movimientos se tenga un mayor desempeño y mejor exactitud en la predicción. Los resultados para la predicción de los movimientos de la mano demostró que el método VMD es el que logra una mayor exactitud en la predicción y clasificación de los movimientos con un 54.67%, pero esto se logra sin segmentar la señal con lo cual no podría ser aplicado a desarrollos en tiempo real. Sin embargo nos da un primer enfoque de como entender las señales sEMG. Los resultados generales de este estudio muestran que se obtienen valores de exactitud por debajo del 60% sin importar los enfoques planteados. Pero de la misma manera nos permite tener buenas conclusiones y observaciones, la metodología de adquisición de señales sEMG tiene un papel muy importante para que las señales sEMG sean obtenidas de la manera más fiable posible. Al implementar el ventaneo en las señales sEMG solo se estarían analizando lapsos de tiempo cortos, pero para la generación de algún movimiento, las señales sEMG no se comportan de igual manera de principio a fin por lo cual analizar la señal completa es mejor ya que nos brinda un panorama general del comportamiento de la señal sEMG desde que comienza la actividad muscular hasta que esta termina dando fin a la manipulación y ejecución del movimiento. Así a medida que el tamaño de ventana aumenta se tienen mejores resultados.

De igual manera los mejores resultados y los más estables son cuando se lleva a cabo el proceso de reducción de la dimensionalidad ya sea para el análisis sin ventaneo o con los diversos tamaños de ventana. Lo cual hace que reducir las características de la señal sea lo más adecuado para este análisis enfocado en el reconocimiento de movimientos. Las pruebas para reducir la redundancia entre sensores planteó el utilizar 5 sensores para tener la mayor cantidad de información referente a diversos músculos del miembro superior, 3 sensores para tener toda la información del antebrazo y un solo sensor el cual plantea tener la información mínima para llevar a cabo la clasificación de movimientos. Se observó que con 5 sensores se tiene la mayor exactitud al momento de reconocer los 6 movimientos taxonómicos, lo cual plantea que se necesita diversa información de distintos músculos del miembro superior para reconocer de manera más eficiente y correcta los diversos movimientos.

Con lo anterior, el reconocer gestos plantea un verdadero reto que implica tener en consideración diversos factores desde los participantes del estudio, la metodología para la adquisición de las señales, el tipo de sensores a utilizar y la forma en que se realiza su análisis. Muchas investigaciones que han utilizado la misma base datos plantea un análisis menos robusto puesto que ellos utilizan a todos los participantes para entrenar y validar su metodología, por lo cual sus resultados presentan mayor exactitud al reconocer los movimientos de la mano que los obtenidos por nuestro análisis en un 20% aproximadamente. En esta tesis se utilizó a los primeros 28 sujetos para entrenar el sistema de clasificación y a los restantes 12 para efectuar la validación. Así que nuestro análisis resulta ser más robusto puesto que no realizamos una mezcla de información de los sujetos que participan en el estudio para conformar la base datos, además que se pretende entender la taxonomía de los movimientos y en utilizar técnicas más modernas en análisis de señales dando también importancia a las características en frecuencia ya que pueden proporcionarnos información valiosa del comportamiento de las señales sEMG.

Conforme a los métodos de descomposición de señales estos si son factibles para la extracción de características que permitan el reconocimiento de movimientos, pero no podrían ser aplicados a enfoques en tiempo real ya que el costo computacional es muy demandante. El no realizar un metodología de descomposición de señales también mostró resultados bastantes semejan-

tes en comparación con los métodos DWT, VMD y EEMD por lo que sería una opción para aplicaciones en tiempo real. De igual manera para mejorar la exactitud del modelo predictivo hace que sea necesario tener otro tipo de señales biomédicas que sirva como retroalimentación o como características, es decir, tener un procesamiento de imágenes para definir el objeto que se pretende manipular, tener información de la forma del objeto así como del material del que esta hecho. Con esto se logra definir explícitamente el movimiento a realizar por lo cual el trabajo futuro plantea el hacer una base de datos con señales sEMG, acelerometría y con análisis de imágenes para mejorar el sistema y que este pueda ser implementado de manera real en una prótesis.

# Bibliografía

- [1] E Vazquez. Los amputados y su rehabilitación, un reto para el estado. *Academia Nacional de Medicina de México. México*, 2016.
- [2] Instituto Nacional de Estadística y Geografía. Estadísticas a propósito del día internacional de las personas con discapacidad, 2019.
- [3] Jianhua Zhang, Chen Ling, and Sunan Li. Emg signals based human action recognition via deep belief networks. *IFAC-PapersOnLine*, 52(19):271–276, 2019.
- [4] K.L. Moore, A.F. Dalley, and A.M.R. Agur. *Anatomía con Orientación Clínica*. Lippincott Williams, Wilkins, 2018.
- [5] Mamun Bin Ibne Reaz, M Sazzad Hussain, and Faisal Mohd-Yasin. Techniques of emg signal analysis: detection, processing, classification and applications. *Biological procedures online*, 8(1):11–35, 2006.
- [6] MA Cavalcanti Garcia and TMM Vieira. Surface electromyography: Why, when and how to use it. *Revista andaluza de medicina del deporte*, 4(1):17–28, 2011.
- [7] Andrew D Vigotsky, Israel Halperin, Gregory J Lehman, Gabriel S Trajano, and Taian M Vieira. Interpreting signal amplitudes in surface electromyography studies in sport and rehabilitation sciences. *Frontiers in physiology*, 8:985, 2018.
- [8] TDRR Moritani, D Stegeman, and R Merletti. Basic physiology and biophysics of emg signal generation. *Electromyography Physiology Engineering and Noninvasive Applications*, pages 1–20, 2004.
- [9] Andrew Michell. *Understanding EMG*. OUP Oxford, 2013.
- [10] Dinesh K Kumar, Beth Jelfs, Xiaohong Sui, and Sridhar P Arjunan. Prosthetic hand control: A multidisciplinary review to identify strengths, shortcomings, and the future. *Biomedical Signal Processing and Control*, 53:101588, 2019.
- [11] Feiyun Xiao, Decai Yang, Zhongming Lv, Xiaohui Guo, Zhengshi Liu, and Yong Wang. Classification of hand movements using variational mode decomposition and composite permutation entropy index with surface electromyogram signals. *Future Generation Computer Systems*, 110:1023–1036, 2020.
- [12] Gang Wang, Yanyan Zhang, and Jue Wang. The analysis of surface emg signals with the wavelet-based correlation dimension method. *Computational and mathematical methods in medicine*, 2014, 2014.
- [13] Jimson G Ngeo, Tomoya Tamei, and Tomohiro Shibata. Continuous and simultaneous estimation of finger kinematics using inputs from an emg-to-muscle activation model. *Journal of neuroengineering and rehabilitation*, 11(1):1–14, 2014.



- [14] Elahe Rahimian, Soheil Zabihi, Seyed Farokh Atashzar, Amir Asif, and Arash Mohammadi. Surface emg-based hand gesture recognition via hybrid and dilated deep neural network architectures for neurorobotic prostheses. *Journal of Medical Robotics Research*, 5(01n02):2041001, 2020.
- [15] Jonathan R Torres-Castillo, Carlos Omar López-López, and Miguel A Padilla-Castañeda. Neuro-muscular disorders detection through time-frequency analysis and classification of multi-muscular emg signals using hilbert-huang transform. *Biomedical Signal Processing and Control*, 71:103037, 2022.
- [16] Manfredo Atzori, Arjan Gijsberts, Simone Heynen, Anne-Gabrielle Mittaz Hager, Olivier Deriaz, Patrick Van Der Smagt, Claudio Castellini, Barbara Caputo, and Henning Müller. Building the ninapro database: A resource for the biorobotics community. In *2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics (BioRob)*, pages 1258–1265. IEEE, 2012.
- [17] Manfredo Atzori, Arjan Gijsberts, Ilja Kuzborskij, Simone Heynen, Anne-Gabrielle Mittaz Hager, Olivier Deriaz, Claudio Castellini, Henning Müller, and Barbara Caputo. A benchmark database for myoelectric movement classification. *Trans. Neural Syst. Rehabil. Eng.*, 2013.
- [18] Manfredo Atzori, Arjan Gijsberts, Claudio Castellini, Barbara Caputo, Anne-Gabrielle Mittaz Hager, Simone Elsig, Giorgio Giatsidis, Franco Bassetto, and Henning Müller. Electromyography data for non-invasive naturally-controlled robotic hand prostheses. *Scientific data*, 1(1):1–13, 2014.
- [19] Ilja Kuzborskij, Arjan Gijsberts, and Barbara Caputo. On the challenge of classifying 52 hand movements from surface electromyography. In *2012 annual international conference of the IEEE engineering in medicine and biology society*, pages 4931–4937. IEEE, 2012.
- [20] Subramanian T Venkataraman and Thea Iberall. *Dextrous robot hands*. Springer Science & Business Media, 2012.
- [21] Francesca Stival, Stefano Michieletto, Matteo Cognolato, Enrico Pagello, Henning Müller, and Manfredo Atzori. A quantitative taxonomy of human hand grasps. *Journal of neuroengineering and rehabilitation*, 16(1):1–17, 2019.
- [22] John R Napier. The prehensile movements of the human hand. *The Journal of bone and joint surgery. British volume*, 38(4):902–913, 1956.
- [23] Mark R Cutkosky et al. On grasp choice, grasp models, and the design of hands for manufacturing tasks. *IEEE Transactions on robotics and automation*, 5(3):269–279, 1989.
- [24] Catherine L Reed and Mounia Ziat. Haptic perception: From the skin to the brain. 2018.
- [25] Jordi Serra Catafau. *Tratado de dolor neuropático*. Ed. Médica Panamericana, 2007.
- [26] Arjan Gijsberts, Manfredo Atzori, Claudio Castellini, Henning Müller, and Barbara Caputo. Movement error rate for evaluation of machine learning methods for semg-based hand movement classification. *IEEE transactions on neural systems and rehabilitation engineering*, 22(4):735–744, 2014.
- [27] Nurhazimah Nazmi, Mohd Azizi Abdul Rahman, Shin-Ichiroh Yamamoto, Siti Anom Ahmad, Hairi Zamzuri, and Saiful Amri Mazlan. A review of classification techniques of emg signals during isotonic and isometric contractions. *Sensors*, 16(8):1304, 2016.
- [28] David P Allen. A frequency domain hampel filter for blind rejection of sinusoidal interference from electromyograms. *Journal of neuroscience methods*, 177(2):303–310, 2009.

- [29] Ronald K Pearson. Outliers in process modeling and identification. *IEEE Transactions on control systems technology*, 10(1):55–63, 2002.
- [30] Laurie Davies and Ursula Gather. The identification of multiple outliers. *Journal of the American Statistical Association*, 88(423):782–792, 1993.
- [31] François Hug. Can muscle coordination be precisely studied by surface electromyography? *Journal of electromyography and kinesiology*, 21(1):1–12, 2011.
- [32] EM Winter and FBC Brookes. Electromechanical response times and muscle elasticity in men and women. *European journal of applied physiology and occupational physiology*, 63(2):124–128, 1991.
- [33] Gary L Soderberg and Loretta M Knutson. A guide for use and interpretation of kinesiology electromyographic data. *Physical therapy*, 80(5):485–498, 2000.
- [34] HI Dubo, MALCOLM Peat, DA Winter, AO Quanbury, DA Hobson, THOMAS Steinke, and GARY Reimer. Electromyographic temporal analysis of gait: normal human locomotion. *Archives of physical medicine and rehabilitation*, 57(9):415–420, 1976.
- [35] Suman Kanti Chowdhury, Ashish D Nimbarte, Majid Jaridi, and Robert C Creese. Discrete wavelet transform analysis of surface electromyography for the fatigue assessment of neck and shoulder muscles. *Journal of Electromyography and Kinesiology*, 23(5):995–1003, 2013.
- [36] Dinesh Kant Kumar, Nemuel D Pah, and Alan Bradley. Wavelet analysis of surface electromyography. *IEEE transactions on neural systems and rehabilitation engineering*, 11(4):400–406, 2003.
- [37] Angkoon Phinyomark, Chusak Limsakul, and Pornchai Phukpattaranont. Application of wavelet analysis in emg feature extraction for pattern classification. *Measurement Science Review*, 11(2):45, 2011.
- [38] Vimal Shanmuganathan, Harold Robinson Yesudhas, Mohammad S Khan, Manju Khari, and Amir H Gandomi. R-cnn and wavelet feature extraction for hand gesture recognition with emg signals. *Neural Computing and Applications*, 32(21):16723–16736, 2020.
- [39] Norden Eh Huang. *Hilbert-Huang transform and its applications*, volume 16. World Scientific, 2014.
- [40] Norden E Huang, Zheng Shen, Steven R Long, Manli C Wu, Hsing H Shih, Quanan Zheng, Nai-Chyuan Yen, Chi Chao Tung, and Henry H Liu. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, 454(1971):903–995, 1998.
- [41] Cong Zong and Mohamed Chetouani. Hilbert-huang transform based physiological signals analysis for emotion recognition. In *2009 IEEE international symposium on signal processing and information technology (ISSPIT)*, pages 334–339. IEEE, 2009.
- [42] Dejie Yu, Junsheng Cheng, and Yu Yang. Application of emd method and hilbert spectrum to the fault diagnosis of roller bearings. *Mechanical systems and signal processing*, 19(2):259–270, 2005.
- [43] María E Torres, Marcelo A Colominas, Gastón Schlotthauer, and Patrick Flandrin. A complete ensemble empirical mode decomposition with adaptive noise. In *2011 IEEE international conference on acoustics, speech and signal processing (ICASSP)*, pages 4144–4147. IEEE, 2011.

- [44] Said Gaci. A new ensemble empirical mode decomposition (eemd) denoising method for seismic signals. *Energy Procedia*, 97:84–91, 2016.
- [45] Zhaohua Wu and Norden E Huang. Ensemble empirical mode decomposition: a noise-assisted data analysis method. *Advances in adaptive data analysis*, 1(01):1–41, 2009.
- [46] Konstantin Dragomiretskiy and Dominique Zosso. Variational mode decomposition. *IEEE transactions on signal processing*, 62(3):531–544, 2013.
- [47] Yanxue Wang, Fuyun Liu, Zhansi Jiang, Shuilong He, and Qiuyun Mo. Complex variational mode decomposition for signal processing applications. *Mechanical systems and signal processing*, 86:75–85, 2017.
- [48] Pengbo Zheng and Juwei Zhang. Application of variational mode decomposition and k-nearest neighbor algorithm in the quantitative nondestructive testing of wire ropes. *Shock and Vibration*, 2019, 2019.
- [49] Magnus R Hestenes. Multiplier and gradient methods. *Journal of optimization theory and applications*, 4(5):303–320, 1969.
- [50] Dimitri P Bertsekas. *Constrained optimization and Lagrange multiplier methods*. Academic press, 2014.
- [51] Shuo Jiang, Bo Lv, Weichao Guo, Chao Zhang, Haitao Wang, Xinjun Sheng, and Peter B Shull. Feasibility of wrist-worn, real-time hand, and surface gesture recognition via semg and imu sensing. *IEEE Transactions on Industrial Informatics*, 14(8):3376–3385, 2017.
- [52] Mohammadreza Asghari Oskoei and Huosheng Hu. Myoelectric control systems—a survey. *Biomedical signal processing and control*, 2(4):275–294, 2007.
- [53] Arjan Gijsberts, Manfredo Atzori, Claudio Castellini, Henning Müller, and Barbara Caputo. Movement error rate for evaluation of machine learning methods for semg-based hand movement classification. *IEEE transactions on neural systems and rehabilitation engineering*, 22(4):735–744, 2014.
- [54] Ilya Kuzborskij, Arjan Gijsberts, and Barbara Caputo. On the challenge of classifying 52 hand movements from surface electromyography. In *2012 annual international conference of the IEEE engineering in medicine and biology society*, pages 4931–4937. IEEE, 2012.
- [55] Rubana H Chowdhury, Mamun BI Reaz, Mohd Alauddin Bin Mohd Ali, Ashrif AA Bakar, Kalai-vani Chellappan, and Tae G Chang. Surface electromyography signal processing and classification techniques. *Sensors*, 13(9):12431–12466, 2013.
- [56] Sara Abbaspour, Maria Lindén, Hamid Gholamhosseini, Autumn Naber, and Max Ortiz-Catalan. Evaluation of surface emg-based recognition algorithms for decoding hand movements. *Medical & biological engineering & computing*, 58(1):83–100, 2020.
- [57] Angkoon Phinyomark, Pornchai Phukpattaranont, and Chusak Limsakul. Feature reduction and selection for emg signal classification. *Expert systems with applications*, 39(8):7420–7431, 2012.
- [58] Nurhazimah Nazmi, Mohd Azizi Abdul Rahman, Shin-Ichiroh Yamamoto, Siti Anom Ahmad, Hairi Zamzuri, and Saiful Amri Mazlan. A review of classification techniques of emg signals during isotonic and isometric contractions. *Sensors*, 16(8):1304, 2016.
- [59] Lawrence Marple. Computing the discrete-time “analytic” signal via fft. *IEEE Transactions on signal processing*, 47(9):2600–2603, 1999.

- [60] Vipin K Mishra, Varun Bajaj, Anil Kumar, Dheeraj Sharma, and GK Singh. An efficient method for analysis of emg signals using improved empirical mode decomposition. *AEU-International Journal of Electronics and Communications*, 72:200–209, 2017.
- [61] Alan Jović, Karla Brkić, and Nikola Bogunović. A review of feature selection methods with applications. pages 1200–1205, 2015.
- [62] Beatriz Remeseiro and Veronica Bolon-Canedo. A review of feature selection methods in medical applications. *Computers in biology and medicine*, 112:103375, 2019.
- [63] Murray R Spiegel, Alberto Losada Villasante, et al. *Estadística*. 1970.
- [64] Sanjay Yadav and Sanyam Shukla. Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification. In *2016 IEEE 6th International conference on advanced computing (IACC)*, pages 78–83. IEEE, 2016.
- [65] Laurens Van Der Maaten, Eric Postma, Jaap Van den Herik, et al. Dimensionality reduction: a comparative. *J Mach Learn Res*, 10(66-71):13, 2009.
- [66] Shaeela Ayesha, Muhammad Kashif Hanif, and Ramzan Talib. Overview and comparative study of dimensionality reduction techniques for high dimensional data. *Information Fusion*, 59:44–58, 2020.
- [67] Thippa Reddy Gadekallu, Praveen Kumar Reddy, Lakshman Kuruva, Kaluri Rajesh, Dharmendra Singh Rajput, Gautam Srivastava, et al. Analysis of dimensionality reduction techniques on big data, iee access, ieee. march16, 2020 (volume: 8): 54776–54788, 2020.
- [68] Adrain DC Chan and Geoffrey C Green. Myoelectric control development toolbox. *CMBES Proceedings*, 30, 2007.
- [69] Zhong Jin, Jing-Yu Yang, Zhong-Shan Hu, and Zhen Lou. Face recognition based on the uncorrelated discriminant transformation. *Pattern recognition*, 34(7):1405–1416, 2001.
- [70] Jieping Ye, Ravi Janardan, Qi Li, and Haesun Park. Feature reduction via generalized uncorrelated linear discriminant analysis. *IEEE Transactions on Knowledge and Data Engineering*, 18(10):1312–1322, 2006.
- [71] Marina Paolanti and Emanuele Frontoni. Multidisciplinary pattern recognition applications: A review. *Computer Science Review*, 37:100276, 2020.
- [72] Shichao Zhang, Xuelong Li, Ming Zong, Xiaofeng Zhu, and Debo Cheng. Learning k for knn classification. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 8(3):1–19, 2017.
- [73] Shichao Zhang, Xuelong Li, Ming Zong, Xiaofeng Zhu, and Ruili Wang. Efficient knn classification with different numbers of nearest neighbors. *IEEE transactions on neural networks and learning systems*, 29(5):1774–1785, 2017.
- [74] Li-Yu Hu, Min-Wei Huang, Shih-Wen Ke, and Chih-Fong Tsai. The distance function effect on k-nearest neighbor classification for medical datasets. *SpringerPlus*, 5(1):1–9, 2016.
- [75] Davood Mahmoodi, Ali Soleimani, Hossein Khosravi, Mehdi Taghizadeh, et al. Fpga simulation of linear and nonlinear support vector machine. *Journal of Software Engineering and Applications*, 4(05):320, 2011.
- [76] Yun Xu, Simeone Zomer, and Richard G Brereton. Support vector machines: a recent method for classification in chemometrics. *Critical Reviews in Analytical Chemistry*, 36(3-4):177–188, 2006.

- [77] Pang-Ning Tan, Michael Steinbach, and Vipin Kumar. Classification: basic concepts, decision trees, and model evaluation. *Introduction to data mining*, 1:145–205, 2006.
- [78] Arundhati Navada, Aamir Nizam Ansari, Siddharth Patil, and Balwant A Sonkamble. Overview of use of decision tree algorithms in machine learning. In *2011 IEEE control and system graduate research colloquium*, pages 37–42. IEEE, 2011.
- [79] Seema Sharma, Jitendra Agrawal, Shikha Agarwal, and Sanjeev Sharma. Machine learning techniques for data mining: A survey. In *2013 IEEE International Conference on Computational Intelligence and Computing Research*, pages 1–6. IEEE, 2013.
- [80] Madan Somvanshi, Pranjali Chavan, Shital Tambade, and SV Shinde. A review of machine learning techniques using decision tree and support vector machine. In *2016 international conference on computing communication control and automation (ICCUBEA)*, pages 1–7. IEEE, 2016.
- [81] William R Burrows, Mario Benjamin, Stephen Beauchamp, Edward R Lord, Douglas McCollor, and Bruce Thomson. Cart decision-tree statistical analysis and prediction of summer season maximum surface ozone for the vancouver, montreal, and atlantic regions of canada. *Journal of Applied Meteorology and Climatology*, 34(8):1848–1862, 1995.

# Anexos

## 6.1. Sistema de adquisición de señales sEMG

Con el desarrollo de esta tesis se busca el tener una metodología para el análisis de señales sEMG que sea óptimo en el reconocimiento de movimientos de la mano para posteriormente ser aplicada al desarrollo de prótesis de mano con control electromiográfico. Debido a los altos costos en los equipos de adquisición de señales sEMG se optó por desarrollar nuestro propio sistema que nos permitiera adquirir las señales sEMG de manera inalámbrica permitiéndonos utilizarlo en diversos desarrollos y pruebas experimentales. El sistema de adquisición desarrollado consta de 8 canales sEMG los cuales pueden ser muestreados a una frecuencia de  $1\text{ kHz}$ . Dicha frecuencia de muestreo cumple el criterio de Nyquist el cual dice que la frecuencia a la cual se va a muestrear la señal debe ser por lo menos dos veces la frecuencia de la señal, además también cumple con el estándar SENIAM. El sensor utilizado para obtener las señales fue el MyoWare Muscle Sensor (AT-04-001) (figura 6.1).



Figura 6.1: Sensor MyoWare Muscle Sensor (AT-04-001)

Se diseñó la tarjeta que permitirá la adquisición de las señales, esta tarjeta incluye el microcontrolador que convierte la señal analógica en una señal digital mediante el convertidor ADC (*Analog-to-Digital Converter*) con una resolución de 16 bits. El modelo de este microcontrolador es el Teensy 3.2 ya que por su tamaño y por las características que tiene hace que sea factible su uso en este desarrollo. De la misma manera esta tarjeta posee la antena bluetooth la cual permite transmitir las señales obtenidas a una computadora para su almacenamiento en archivos de excel. En la figura 6.2 se puede visualizar el diseño electrónico de la tarjeta de adquisición y en la figura 6.3 se observa todo el sistema ya implementado con todos los componentes que lo conforman.

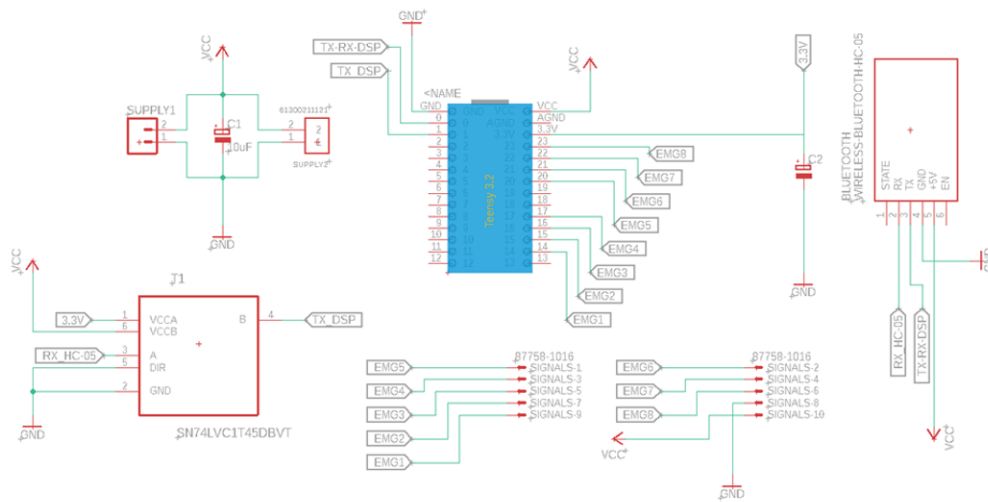


Figura 6.2: Diseño de la tarjeta de adquisición de señales sEMG.

Con este dispositivo se podrán adquirir las señales sEMG para diversos fines de estudio y para distintos experimentos y análisis donde la señal sEMG juegue un papel relevante, como lo es el diagnóstico clínico, medicina del deporte, control de dispositivos protésicos y en la rehabilitación. Lo cual hace que este sistema sea muy versátil gracias a su diseño inalámbrico.




Figura 6.3: Tarjeta de adquisición de señales sEMG.

**Conexión inalámbrica a PC.**  
Establece comunicación entre el sistema de adquisición de datos y la PC

**Adquisición de datos.**  
Con estos botones se inicia o se detiene la adquisición de datos

**Selección de canales.**  
Selección de hasta 8 canales de adquisición sEMG

**Visualización del tiempo de adquisición de datos**

**Se genera un archivo de Excel con los datos obtenidos de todas las señales EMG**

**Graficas.**  
Se grafican las señales EMG adquiridas

**Uso del Software**

1. Seleccionar el número de sensores a utilizar (EMG1 al EMG8).
2. Establecer la comunicación entre el sistema de adquisición y la PC. (Presionando el botón **“Conectar”**)
3. Iniciar la adquisición de datos durante el tiempo requerido presionando el botón **“Iniciar”**
4. Detener la adquisición de datos presionando el botón **“Detener”**
5. Escribir el nombre del archivo Excel a generar en **“Nombre del Archivo”**
6. Generar el archivo Excel presionando el botón **“Generar”**
7. Si se desea visualizar las graficas presionar **“Graficas”**
8. Para iniciar una nueva adquisición de datos repetir pasos del 3 al 6.
9. Si ya se termino el experimento y se desea cerrar el programa de adquisición entonces presionar el botón **“Desconectar”** y posteriormente terminamos la ejecución del software

Figura 6.4: Interfaz de adquisición de señales sEMG.



Las primeras pruebas para la recepción de los datos en la computadora se realizó utilizando el lenguaje de programación python gracias a las facilidades que este plantea. Sin embargo este no era intuitivo puesto que se basa en la ejecución directa del código de programación y se requiere tener algún tipo de conocimiento en este lenguaje, por lo tanto se realizó el diseño de una interfaz gráfica que mitigara esos inconvenientes. La interfaz gráfica que permite la adquisición de señales sEMG se desarrolló de igual manera en python y tuvo como objetivo hacer mas intuitivo la selección de los canales sEMG, el establecimiento de la comunicación bluetooth con la computadora, el inicio y final de la adquisición de las señales y la generación de los archivos que contienen los valores de las señales, lo cual hace que cualquier persona pueda utilizar el sistema.

## 6.2. Desarrollo de la prótesis de mano

Se esta desarrollando la construcción de la mano robótica que permitirá poner en ejecución el control electromiográfico para la generación de movimientos. Dicha construcción de la mano se toma del proyecto ProHand (<http://ninapro.hevs.ch/ProHand>) la cual consta de una mano protésica impresa en 3D (Handi Hand) la cual puede ser instrumentada con diversos sensores para tener distintas retroalimentaciones al momento de realizar un agarre y este se pueda ejecutar de la manera más fiable y natural posible.




Figura 6.5: Mano protésica Handi Hand

Para que se pueda controlar la mano protésica hace que sea necesario una tarjeta de adquisición para las retroalimentaciones generadas para los distintos sensores con las que se va a instrumentar la mano, así como para la generación de los comandos de control que permita la manipulación en el giro de los servomotores los cuales tendrán la función de flexión y extensión de los dedos así como del giro del pulgar. La figura 6.6 muestra el diseño de la tarjeta que permitirá la adquisición de las señales generadas por los sensores así como de la generación de los comandos de control para cada uno de los servomotores.

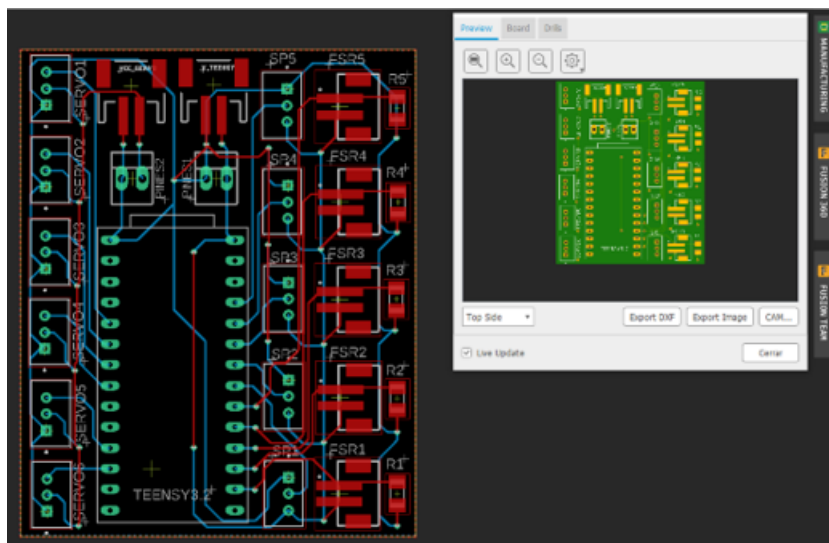
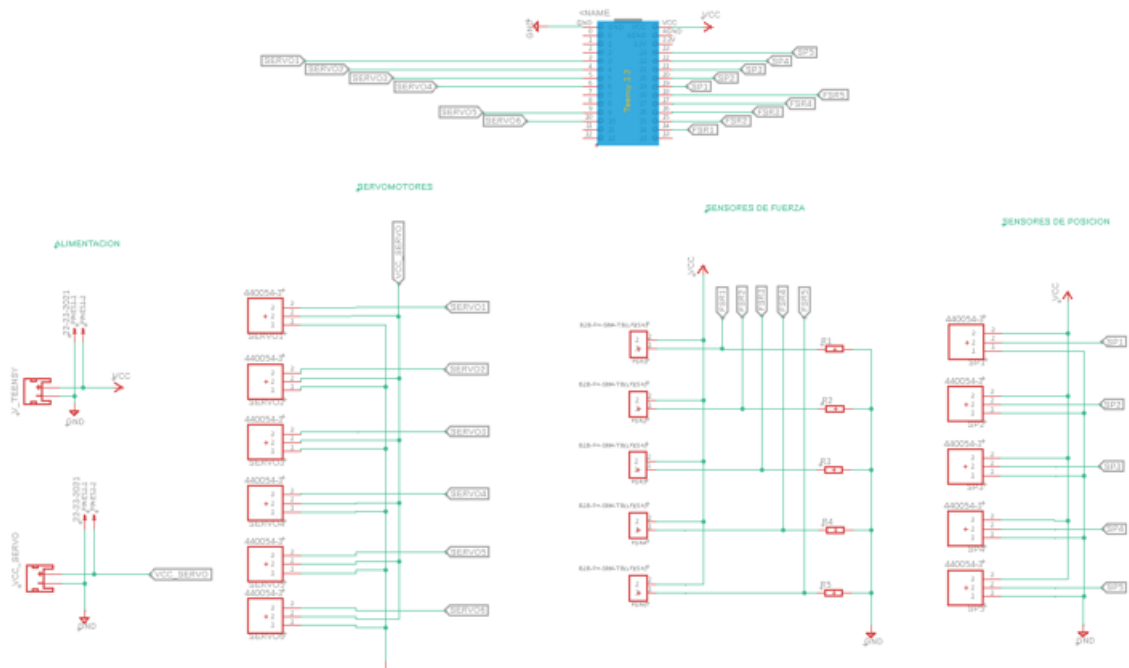


Figura 6.6: Circuito para el control de la mano robótica.