

**CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS  
DEL INSTITUTO POLITÉCNICO NACIONAL**

UNIDAD ZACATENCO  
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA  
SECCIÓN DE BIOELECTRÓNICA

Sistema clasificador de movimientos de la extremidad superior  
humana con información de sEMG y de un estimador de orientación 3D  
para el control de un modelo virtual

**Tesis que presenta**

Leonardo Misael Delgadillo De La Torre

**para obtener el Grado de**

**Maestro en Ciencias**

**en la Especialidad de**

Ingeniería Eléctrica

**Codirectores de la Tesis:** Dr. Lorenzo Leija Salas  
Dr. Carlos Alvarado Serrano





## **Agradecimientos**

A mis padres, a mi hermana, a mi tía Amanda, mi familia fue mi apoyo y siempre me otorgaron motivación más que suficiente para realizar este trabajo.

A mis compañeros de laboratorio Esme, Anaís, Luis, Ángeles, Ismael Cosme, Ismael, Pedro y a Bere por su apoyo en ese espacio de aprendizaje, con especial mención de Miguel, Armando y a Adri, porque su saber y opinión han influido mucho en aspectos importantes de mi vida actual. A los chicos de estancia Karen, Saic y Guadalupe quienes grabaron en mí gratos recuerdos del periodo que trabajaron en el laboratorio. A todos mis compañeros de generación y especialmente a Joaquin, Martín y Sarai, ya que en ellos encontré el significado de amistad, alegría y perseverancia.

Al doctor Roberto por darme la oportunidad de colaborar con él en su laboratorio y a Linda por otorgarme los elementos para desarrollar esta tesis. Al doctor Juan que me presentó las herramientas que permitieron llevar a cabo este trabajo. A mis profesores ya que su conocimiento me sirvió de guía para desarrollar este tema con especial mención del doctor Pablo Rogelio, de quien desde siempre conté con su apoyo y que además fue para mí un ejemplo de sabiduría y humildad.

Al doctor Leija y al doctor Alvarado por integrarme a su equipo de trabajo para continuar la dirección de este proyecto.

A todos aquellos que compartieron su tiempo en este estudio, ya que sin su ayuda no hubiera sido posible concluir este trabajo, principalmente a Chabelita y a Toño ya que su apoyo moral y académico fue invaluable.



Agradezco al CONACyT por el apoyo económico que me otorgó para construirme como investigador y al CINVESTAV por ser la casa de estudios que me permitió aplicar mis habilidades a la noble labor de la investigación.



## Resumen

La clasificación de movimientos articulares a través de electromiografía es afectada por el cambio de la orientación de la extremidad superior. Esta acción produce errores en la predicción de los clasificadores de movimientos articulares basados en electromiografía, por lo que investigadores del campo de la inteligencia artificial se han dedicado a reducir dicho efecto.

En este estudio se desarrolla un método de clasificación que permite identificar cuatro tipos de movimientos, de las articulaciones del codo y del antebrazo, en tres diferentes orientaciones de la extremidad superior. Para reconocerlos se realizó un clasificador que usa como valores de entrada tanto características extraídas de las señales eléctricas de dos músculos del brazo, así como también utiliza la información de un sistema que estima la orientación espacial de la extremidad mencionada.

El clasificador puede identificar cuatro tipos de movimientos articulares de la extremidad superior en tres distintas posiciones corporales. En un modelo virtual fueron representadas las predicciones realizadas por este clasificador para demostrar su funcionamiento. Es importante destacar que un aporte de este trabajo es que los resultados de las clasificaciones se obtuvieron del análisis de las contracciones dinámicas de los músculos a pesar de que el comportamiento de las señales electromiográficas en este estado suelen ser altamente estocásticas.

Las pruebas realizadas en este trabajo con 10 sujetos muestran con un nivel de confianza del 95% que la información de la orientación tridimensional estimada del brazo incrementa significativamente las predicciones basadas en su electromiografía. Se creó un clasificador de movimientos del antebrazo, se realizaron pruebas en distintas posiciones corporales y los resultados obtenidos invitan a seguir promoviendo así su uso para en un trabajo futuro continuar mejorando el desarrollo de técnicas de control de dispositivos orientados a complementar o suplir las funciones de la extremidad superior como exoesqueletos, órtesis y prótesis.



## **Abstract**

The classification of joint movements through electromyography is affected by the change in orientation of the upper y extremity. This action produce error in the classifier's prediction, which is so that researchers in the artificial intelligence field have focused on reduce this effect.

In this study is developed a classification method that allows identifying four types of movements, of the elbow and forearm joints, in three different orientations of the upper extremity. To recognize them the classifier developed uses as input values both features extracted from the electrical signals of two muscles of the arm, with the information of a system that determines the spatial orientation of the mentioned limb.

The classifier can identify four types of joint movements of the upper extremity in three different body positions. In a virtual model the predictions made by this classifier were shown to demonstrate its functioning. It is important to emphasize that a contribution of this work is that the results of the classifications were obtained from the analysis of the dynamic contractions of the muscles even though the behavior of the electromyographic signals in this state are usually highly stochastic.

The tests carried out in this work with 10 test subjects show with a confidence level of 95% that the information of the estimated three-dimensional orientation of the arm significantly increases the predictions based on its electromyography. A forearm movement classifier was created, test were performed in different body positions and the result obtained invite to continue promoting their use for a future work to continue improving the development of device control techniques aimed at complementing or supplying the functions of the upper extremity such as exoskeletons, orthoses and prostheses.



# Contenido

<b>AGRADECIMIENTOS.....</b>	<b>I</b>
<b>RESUMEN .....</b>	<b>III</b>
<b>ABSTRACT.....</b>	<b>IV</b>
<b>1) INTRODUCCIÓN.....</b>	<b>1</b>
1.1) PLANTEAMIENTO DEL PROBLEMA.....	1
1.2) OBJETIVOS .....	3
1.2.1) <i>Objetivo general</i> .....	3
1.2.2) <i>Objetivos particulares</i> .....	3
1.3) ESTRUCTURA DE LA TESIS .....	4
<b>2) ANTECEDENTES Y ESTADO DEL ARTE .....</b>	<b>6</b>
2.1) BIOMECÁNICA DE LA ARTICULACIÓN DEL HOMBRO .....	6
2.2) BIOMECÁNICA DE FLEXIÓN Y EXTENSIÓN DEL CODO.....	8
2.3) BIOMECÁNICA DE PRONACIÓN Y SUPINACIÓN DEL ANTEBRAZO .....	8
2.4) SEÑAL ELECTROMIOGRÁFICA .....	9
2.4.1) <i>Electromiografía</i> .....	9
2.4.2) <i>Potenciales de acción de unidades motoras y banda de frecuencia del EMG</i> .....	10
2.4.3) <i>Estados del EMG</i> .....	11
2.4.4) <i>Ruido en el EMG</i> .....	12
2.5) RECONOCIMIENTO DE PATRONES.....	14
2.6) APRENDIZAJE SUPERVISADO.....	14
2.7) CARACTERÍSTICAS DE MES.....	16
2.8) CARACTERÍSTICAS EN EL DOMINIO TIEMPO-FRECUENCIA .....	17
2.9) TRANSFORMACIÓN DE WAVELET DISCRETA.....	19
2.10) LONGITUD DE VENTANA Y ESTACIONARIEDAD .....	22
2.11) RED NEURONAL PERCEPTRÓN MULTICAPA .....	22
2.12) SENSIBILIDAD, ESPECIFICIDAD Y EXACTITUD .....	25
2.13) ANÁLISIS INFERENCIAL .....	26
2.14) MODELO VIRTUAL DE EXTREMIDAD SUPERIOR .....	27
2.15) ESTADO DEL ARTE .....	28
<b>3) DESARROLLO.....</b>	<b>33</b>
3.1) SOLUCIÓN PROPUESTA.....	33



## Contenido

3.2)	MOVIMIENTOS ANALIZADOS.....	36
3.3)	POSICIONES CORPORALES.....	36
3.4)	MÚSCULOS SENSADOS .....	36
3.5)	FRECUENCIA DE MUESTREO DEL SISTEMA DE ADQUISICIÓN DE LOS EMG.....	37
3.6)	DISPOSITIVOS UTILIZADOS PARA LOS REGISTROS.....	38
3.6.1)	<i>Equipo de cómputo para registro y procesamiento.....</i>	38
3.6.2)	<i>Tarjeta SHIELD-EKG-EMG Olimex.....</i>	38
3.6.3)	<i>Electrodos SHIELD-EKG-EMG-PA Olimex.....</i>	39
3.6.4)	<i>Modificación de las tarjetas SHIELD-EMG-EKG Olimex.....</i>	40
3.6.5)	<i>Tarjeta de adquisición de los registros.....</i>	42
3.6.6)	<i>Fuente de alimentación para la tarjeta de adquisición.....</i>	43
3.6.7)	<i>Descripción del Sistema de orientación 3D .....</i>	44
3.6.8)	<i>Bandas elásticas sujetadoras.....</i>	46
3.6.9)	<i>Acondicionamiento de brazaletes para los electrodos SHIELD EMG-EKG-PA Olimex .....</i>	47
3.7)	SELECCIÓN DE CARACTERÍSTICAS PARA LAS OBSERVACIONES DE ENTRADA DE LA ANN .....	48
3.7.1)	<i>Características extraídas del sistema de orientación 3D .....</i>	48
3.7.2)	<i>Características extraídas del Sistema de electromiografía .....</i>	49
3.8)	ADQUISICIÓN CON LA TARJETA SHIELD DE OLIMEX .....	50
3.9)	ENTRENAMIENTO GUIADO POR PANTALLA .....	50
3.10)	PROTOCOLO DE REGISTROS.....	51
3.11)	ADQUISICIÓN DE LA INFORMACIÓN DE LOS EMG Y DE ORIENTACIÓN 3D .....	56
3.12)	TÉCNICA DE INTELIGENCIA ARTIFICIAL USADA EN EL ESTUDIO.....	58
3.13)	PROCESAMIENTO DE LOS REGISTROS .....	58
<b>4)</b>	<b>PRUEBAS Y RESULTADOS .....</b>	<b>60</b>
4.1)	VERIFICACIÓN DE ANCHO DE BANDA DEL EQUIPO DE ELECTROMIOGRAFÍA.....	60
4.2)	VALIDACIÓN CRUZADA <i>HOLD-OUT</i> .....	62
4.3)	BALANCE DE LOS CONJUNTOS DE DATOS.....	63
4.4)	PARTICIONAMIENTO DE LOS DATOS .....	63
4.5)	FUNCIONES DE ENTRENAMIENTO DE LA MLPNN .....	65
4.6)	SELECCIÓN DE FUNCIÓN WAVELET .....	65
4.7)	CARACTERÍSTICAS DE LAS OBSERVACIONES DE ENTRADA DE LA ANN .....	69
4.8)	METODOLOGÍA DEL ENTRENAMIENTO DE LA ANN .....	70
4.9)	MÉTODOS ESTADÍSTICOS.....	71
4.10)	VERIFICACIÓN DE LOS MODELOS CON EL CONJUNTO DE PRUEBA .....	72





## Contenido

4.11)	COMPARACIÓN DE RESULTADOS SIN EL USO DE LA ORIENTACIÓN 3D.....	78
4.12)	DEMOSTRACIÓN DE CLASIFICACIONES A TRAVÉS DEL MODELO VIRTUAL.....	80
5)	<b>DISCUSIÓN .....</b>	<b>84</b>
6)	<b>CONCLUSIONES .....</b>	<b>86</b>
	<b>ANEXO A. MODIFICACIÓN FÍSICA DE LA TARJETA <i>SHIELD EMG-EKG</i> OLIMEX .....</b>	<b>97</b>
	<b>ANEXO B. ESQUEMÁTICO DE LA TARJETA <i>SHIELD-EMK-EMG</i> OLIMEX.....</b>	<b>98</b>



## Índice de figuras

FIG. 1. MOVIMIENTOS EN LOS PLANOS CORPORALES SAGITAL, CORONAL Y TRANSVERSAL [5] .....	7
FIG. 2. FLEXIÓN-EXTENSIÓN DEL CODO [7] .....	8
FIG. 3. PRONACIÓN-SUPINACIÓN DEL ANTEBRAZO [10] .....	9
FIG. 4. PROCESO DE OBTENCIÓN DE UNA SEÑAL DE ELECTROMIOGRAFÍA [12] .....	10
FIG. 5. ESQUEMA DE APRENDIZAJE SUPERVISADO EN RECONOCIMIENTO DE PATRONES .....	15
FIG. 6. ENTRENAMIENTO DE UN CLASIFICADOR DEL ESQUEMA DE APRENDIZAJE SUPERVISADO .....	15
FIG. 7 WAVELET ORTOGONAL DAUBECHIES 8 .....	19
FIG. 8. DESCOMPOSICIÓN MULTIRRESOLUCIÓN CON DWT [40] .....	21
FIG. 9. FUNCIÓN DE ACTIVACIÓN TANGENTE HIPERBÓLICA [46] .....	23
FIG. 10. RED NEURONAL PERCEPTRÓN MULTICAPA [48] .....	24
FIG. 11. MODELO VIRTUAL DE EXTREMIDAD SUPERIOR [52] .....	27
FIG. 12. ETAPAS DE LA SOLUCIÓN PROPUESTA .....	33
FIG. 13. DIAGRAMA DE BLOQUES DE LA SOLUCIÓN PROPUESTA .....	34
FIG. 14. POSICIÓN DE LOS CANALES DIFERENCIALES DEL TRÍCEPS Y DEL BÍCEPS [64], [65] .....	37
FIG. 15. TARJETA SHIELD-EKG-EMG-OLIMEX [70] .....	39
FIG. 16. ELECTRODOS SHIELD-EMG-EKG-PA OLIMEX [72] .....	40
FIG. 17. FILTRO ACONDICIONADOR DE SEÑAL MODIFICADO .....	41
FIG. 18. TARJETA ARDUINO UNO REV 3 [73] .....	42
FIG. 19. EMPAQUETADO DE BATERÍA 2UR18650Y DE 1850 MAH [74] .....	43
FIG. 20. MÓDULOS DE MONITOREO Y DE COMANDO DEL SISTEMA QUE ESTIMA LA ORIENTACIÓN [4] .....	45
FIG. 21. TIPO DE BANDA ELÁSTICA UTILIZADA EN EL ESTUDIO .....	47
FIG. 22. BRAZALETE MODIFICADO CON CAPACIDAD DE RODEAR EXTREMIDADES MÁS VOLUMINOSAS .....	47
FIG. 23. REPRESENTACIÓN DE EXTRACCIÓN DE 7 CARACTERÍSTICAS POR CADA VENTANA RECONSTRUIDA .....	49
FIG. 24. EJEMPLO DEL ENTRENAMIENTO GUIADO POR PANTALLA [76] .....	51
FIG. 25. REGIÓN DELTOIDEA LATERAL [78] .....	52
FIG. 26. DIVISION TOPOGRÁFICA DEL ABDOMEN [79] .....	53
FIG. 27. FOTOGRAFÍA DE COLOCACIÓN DE LOS DISPOSITIVOS DE ADQUISICIÓN .....	54
FIG. 28. DIAGRAMA DE SECUENCIA DE EVENTOS DURANTE UN REGISTRO .....	57
FIG. 29. CABLE DIVISOR DE SEÑAL DE CONECTOR TIPO JACK DE 3.5 MM .....	60
FIG. 30. COMPORTAMIENTO DEL ESPECTRO DE POTENCIAS. A) SEÑAL ADC0 B) SEÑAL ADC1 .....	61
FIG. 31. COMPORTAMIENTO DEL ESPECTRO DE POTENCIAS. A) SEÑAL ADC0 B) SEÑAL ADC1 FILTRADA .....	62
FIG. 32. VALIDACIÓN CRUZADA HOLD-OUT [83] .....	63
FIG. 33. FUNCIONES WAVELETS MADRE CON MEJOR RENDIMIENTO .....	68



## Contenido

FIG. 34 FUNCIÓN WAVELET COIFLET 5 .....	68
FIG. 35. MATRIZ DE CONFUSIÓN Y REPRESENTACIÓN GRÁFICA DEL CÁLCULO DE LA SENSIBILIDAD Y ESPECIFICIDAD DE SU CLASE A [90]	76
FIG. 36. DIFERENCIA ENTRE LAS SENSIBILIDADES CON DIFERENTES ALGORITMOS DE ENTRENAMIENTO.....	77
FIG. 37. DIAGRAMA DE CAJA DEL MODELO TRAINLM CON Y SIN GRADOS EULER .....	78





## 1) Introducción

### 1.1) Planteamiento del problema

Técnicas del campo de la inteligencia artificial como las redes neuronales artificiales (ANN) son utilizadas para reconocimiento de patrones de la señal electromiográfica (EMG) y se aplican en la identificación de movimientos articulares para el control de prótesis y órtesis en áreas como la robótica y la ingeniería de rehabilitación.

La tecnología actual ha permitido la rehabilitación de personas que tienen sus capacidades motrices disminuidas e incluso también de aquellas que han perdido funciones motrices en su totalidad. El uso de técnicas como la electromiografía, el procesamiento de señales y las ANN permiten predecir la intención de la contracción de los músculos. Identificar estas intenciones, ha dado cabida al término de control electromiográfico, el cual es aplicado a dispositivos electrónicos que asisten o suplen el movimiento de su usuario.

La contracción de los músculos esqueléticos puede producir el movimiento de las extremidades; estas acciones musculares producen señales eléctricas musculares o mioeléctricas (MES), las cuales son proporcionales al nivel de contracción muscular cuando se estimulan y contraen las fibras musculares, por ejemplo, se producen en el bíceps braquial del brazo cuando se flexiona el codo.

Sin embargo pocos sistemas que utilizan MES están siendo implementados clínicamente debido a que los movimientos que se logran reconocer correctamente sólo se basan en una posición corporal, es decir, en una única orientación tridimensional (3D). De esta manera, la información que se obtiene es limitada por las posiciones corporales con las que fue entrenado el modelo computacional clasificador.

La clasificación de movimientos articulares a través de electromiografía es afectada por la orientación de la extremidad superior, es decir, influye en la MES la posición



corporal (la cual permite mantener la articulación del hombro). Este motivo produce un error de las predicciones del clasificador, por lo que muchos investigadores del campo de la inteligencia artificial se han dedicado a disminuir su efecto incluso incluyendo también como información la posición exacta del miembro superior [1].

Es importante reiterar que en todas aquellas actividades en donde se requiere mover la extremidad superior en distintas posiciones, las diferencias de posición disminuyen de manera significativa el desempeño del control mioeléctrico.

Por lo general no son tomadas en cuenta particularidades como la posición corporal en el diseño de sistemas que predicen movimientos, pudiendo ser la información de la orientación estimada del miembro superior respecto a un punto de referencia del cuerpo un factor para mejorar la predicción de estos sistemas.

León [2] y Boschmann [3] demuestran que la posición del miembro superior influye en la clasificación de los movimientos articulares. En esos estudios se observó un buen desempeño de los clasificadores entrenados en diferentes orientaciones, dándoles así aplicación en más de una sola posición corporal.

En este estudio se desarrolla un método de clasificación capaz de funcionar en distintas orientaciones 3D de la extremidad superior. Para predecir movimientos de las articulaciones del codo y del antebrazo, se realiza un modelo clasificador que usa como valores de entrada características extraídas de las señales eléctricas de músculos del brazo, en conjunto con la información de un sistema que estima la orientación 3D de la extremidad mencionada. Finalmente en la clasificación de movimientos articulares a través de un esquema de reconocimiento de patrones se analiza si es un factor determinante el uso de la orientación 3D, que un sistema desarrollado en otro estudio calcula [4].



## 1.2) Objetivos

### 1.2.1) Objetivo general

- Desarrollar un modelo computacional que clasifique cuatro tipos de movimientos de la extremidad superior con información tanto de las señales mioeléctricas de los músculos del brazo, como de un sistema estimador de su orientación 3D, para el control de un modelo virtual.

### 1.2.2) Objetivos particulares

- Modificar el hardware para adquirir electromiografía de superficie en un espectro frecuencial de 0.1 Hz a 500 Hz.
- Integrar el hardware de adquisición de electromiografía de superficie con un sistema que calcula la orientación de la extremidad bajo análisis.
- Registrar señales electromiográficas de forma simultánea con el sistema que estima la orientación de la extremidad superior en tres posiciones corporales diferentes.
- Clasificar los movimientos seleccionados en este estudio usando la orientación de la extremidad superior en conjunto con la información extraída de las señales electromiográficas de la extremidad bajo análisis.
- Demostrar el aporte de usar la orientación tridimensional estimada del brazo y comprobar el funcionamiento del modelo propuesto utilizando como herramienta un modelo virtual de la extremidad superior que represente las predicciones del clasificador de movimientos desarrollado.



### 1.3) Estructura de la tesis

En el capítulo 1 de este trabajo se introduce al lector en el campo del control de prótesis a través de la electromiografía y se presentan los principios del problema que se aborda en este escrito. Además se informa al lector que el objetivo de este proyecto está enfocado a incrementar el porcentaje de clasificaciones correctas de los movimientos realizados por el antebrazo al incluir información de la orientación 3D estimada del brazo en el clasificador.

El capítulo 2 se orienta a sentar las bases del conocimiento utilizado para desarrollar este trabajo. Se introducen los movimientos que serán reconocidos, se abordan los principios de la electromiografía, se presenta la definición del aprendizaje supervisado y su aplicación en el reconocimiento de patrones. Igualmente herramientas como las redes neuronales multicapa y la transformada wavelet discreta son introducidas en este apartado. Como estado del arte se presentan los trabajos que con el reconocimiento de patrones han mejorado el manejo de prótesis de forma natural al incrementar del número de movimientos identificados y principalmente discriminando movimientos en diferentes posiciones corporales del brazo.

El capítulo 3 se enfoca en describir el procedimiento realizado para llevar a cabo esta investigación. Se comienza el capítulo detallando las tres etapas principales en las que se desarrolló el proyecto: adquisición, clasificación y aplicación del modelo. A su vez se describe el protocolo de adquisición de los movimientos a reconocer, el hardware usado para su registro, la extracción de características de las señales obtenidas de dicho registro y el método de validación del modelo computacional desarrollado para clasificar los movimientos.

El capítulo 4 detalla las pruebas realizadas mencionadas en el capítulo 3. Entre otras cosas se describe la selección de los parámetros de la técnica de aprendizaje supervisado empleada, se especifica el método de validación del modelo clasificador





desarrollado y se muestran en tablas los resultados de la validación de diferentes configuraciones de dicho modelo.

En el capítulo 5 se comparan los resultados obtenidos con trabajos previos de reconocimiento de patrones que usaron metodologías diferentes basadas en electromiografía para clasificar movimientos de la extremidad superior.

Finalmente el capítulo 6 se dedica a hacer un compendio de los aportes de esta tesis al reconocimiento de patrones basado en electromiografía. Se concluye mencionando el trabajo futuro que puede derivarse de la contribución del presente trabajo.



## 2) Antecedentes y estado del arte

Este capítulo está orientado a sentar las bases para la comprensión del tema de estudio. Esta sección presenta una breve introducción al esquema de control mioeléctrico utilizado y también al sistema usado para estimar la orientación tridimensional (3D por su abreviatura en inglés) de la extremidad superior. Se exponen trabajos relacionados con la identificación electromiográfica de los cuatro movimientos de interés de este proyecto y también se muestran otros relativos al tema de la estimación de la posición y la orientación de la extremidad superior. De igual modo se abordan temas relacionados con las características del funcionamiento del músculo y también se explican herramientas estadísticas y de inteligencia artificial utilizadas en este trabajo.

### 2.1) Biomecánica de la articulación del hombro

La cintura escapular, conocida generalmente como hombro, es la articulación más móvil del cuerpo humano. Dicha característica le confiere al hombro tres ejes de trabajo y tres grados de libertad. En los tres planos anatómicos imaginarios se realizan los movimientos básicos que permite esta articulación [5]. El plano sagital atraviesa longitudinalmente el cuerpo dividiéndolo en mitad derecha y en mitad izquierda; el plano coronal divide el cuerpo en parte anterior y parte posterior; el plano transversal atraviesa horizontalmente el cuerpo dividiéndolo en parte inferior y en parte superior (Fig. 1).

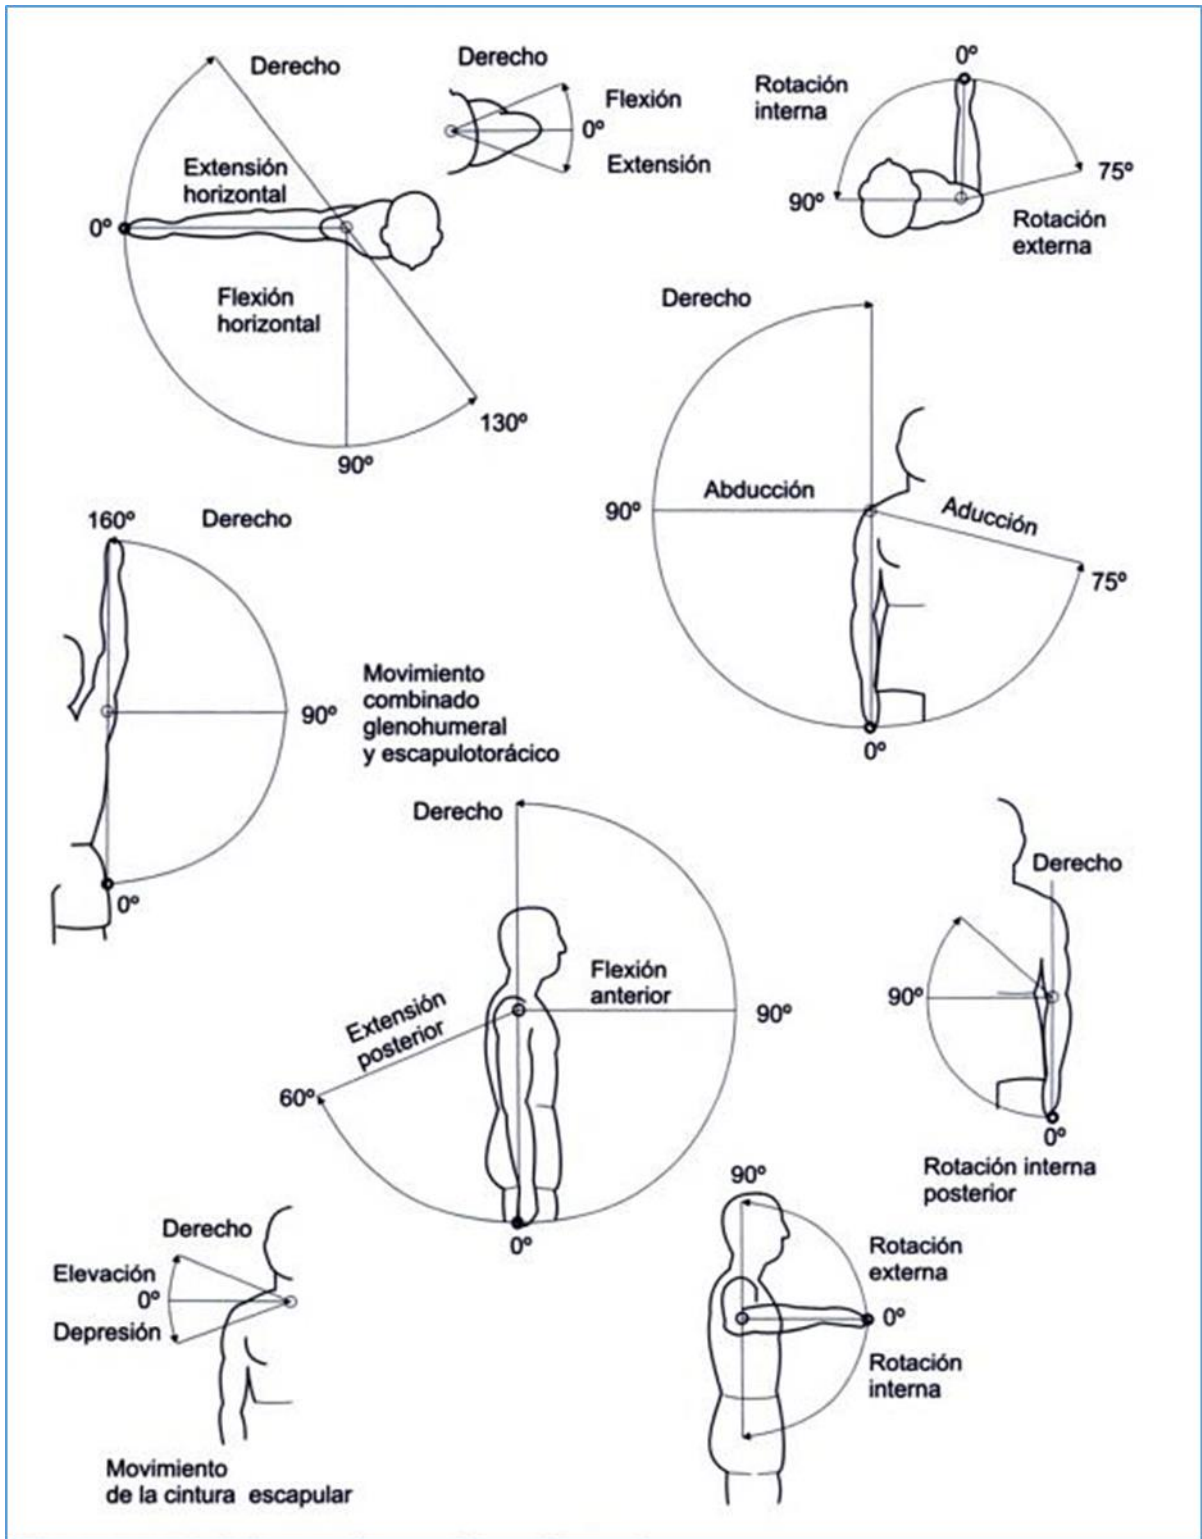


Fig. 1. Movimientos en los planos corporales sagital, coronal y transversal [5]



## 2.2) Biomecánica de flexión y extensión del codo

Durante el movimiento de flexión el antebrazo se mueve en sentido antihorario hasta que el contacto entre el brazo y el antebrazo impide la continuación de este movimiento. El movimiento de flexión es realizado debido a la contribución del músculo braquial, del bíceps braquial y del braquiorradial [6] (Fig. 2).

Por otro lado, el movimiento de extensión es el movimiento del antebrazo en dirección posterior. Dicho movimiento, es limitado por la tensión de la cápsula articular anterior, los músculos flexores y por las porciones anteriores de los ligamentos colaterales. La extensión voluntaria del antebrazo es debida a la acción del músculo tríceps braquial y del ancóneo [6] (Fig. 2).

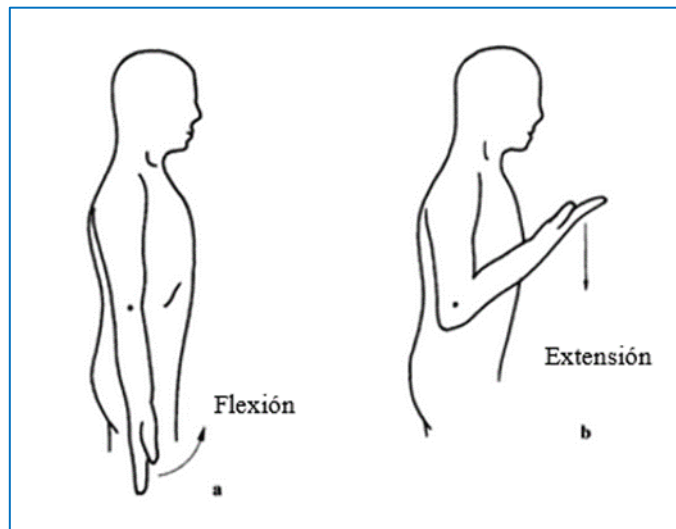


Fig. 2. Flexión-extensión del codo [7]

## 2.3) Biomecánica de pronación y supinación del antebrazo

La pronación y la supinación son movimientos de rotación del antebrazo en torno a su eje longitudinal. En la supinación intervienen el supinador corto y el bíceps; en la pronación actúan el pronador cuadrado y el pronador redondo [8] (Fig. 3). Según Basmajian [9] el bíceps suele activarse cuando se supina el antebrazo en cualquier situación mientras el codo se encuentre en flexión.




Fig. 3. Pronación-supinación del antebrazo [10]

## 2.4) Señal electromiográfica

Las señales electromiográficas o mioeléctricas (MES, por sus siglas en inglés) son señales eléctricas producidas por los músculos durante su proceso de contracción y relajación. La información que se puede extraer de estas señales es utilizada para generar comandos de control; esto se hace actualmente para manipular miembros artificiales utilizados en rehabilitación como las prótesis mioeléctricas. Para poder obtener esta información estas señales son monitoreadas y registradas con una técnica llamada electromiografía.

### 2.4.1) Electromiografía

La electromiografía es una técnica que permite el estudio de la MES, aunque generalmente se usa con fines de diagnóstico de enfermedades en los músculos o en el sistema nervioso hoy en día se puede usar para para controlar dispositivos activos como prótesis u órtesis. La señal electromiográfica es la manifestación eléctrica de la activación de los músculos durante la contracción y la relajación muscular. Al registro gráfico de la señal eléctrica del músculo se le llama electromiograma (EMG) [11]. Se logra apreciar un método de extracción de señal de electromiografía en la siguiente figura (Fig. 4) [9]; se inicia con la colocación de los electrodos para monitorear actividad eléctrica en el músculo; se continua con su amplificación y se finaliza con su filtraje para eliminar señales interferentes. Este método de adquisición de la MES representa



a grandes rasgos la etapa acondicionamiento que se usa generalmente para registrar la actividad eléctrica de las contracciones musculares.




Fig. 4. Proceso de obtención de una señal de electromiografía [12]

Los equipos de electromiografía cuyo fin es el registro y análisis de los potenciales de acción en el músculo están compuestos por electrodos de superficie o de aguja que captan la señal. Con fines de diagnóstico médico o control mioeléctrico una vez acondicionadas las MES se digitalizan para analizarse y procesarse posteriormente.

#### 2.4.2) Potenciales de acción de unidades motoras y banda de frecuencia del EMG

Las motoneuronas emiten impulsos para controlar las fibras musculares que inervan. La motoneurona y el conjunto de todas las fibras musculares inervadas por la misma constituyen una unidad motora. Generalmente se trabaja con los llamados potenciales de acción de unidades motoras (MUAP, por sus siglas en inglés) debido a que no es posible aislar un potencial de acción motor (MAP, por sus siglas en inglés) individual; el MAP produce la forma de onda resultante de la despolarización del sarcolema que origina la contracción de las miofibrillas musculares. Los MUAP generan una forma de onda más detectable, la cual se compone de la sumatoria espacio-temporal de los MAP originados de las fibras musculares en la vecindad de un electrodo o de un par de electrodos [13].



El intervalo de interpulsos (IPI, por sus siglas en inglés) es el tiempo entre descargas de una unidad motora. La frecuencia de estimulación es el inverso del IPI aunque las unidades motoras no son estimuladas en intervalos constantes. Por ejemplo durante una contracción isométrica, a fuerza constante, la frecuencia de activación decrece; es decir, la estimulación de la unidad motora es un proceso dependiente del tiempo [14].

Los MUAP producen diferentes morfologías en la MES y partiendo de la premisa de que las descargas de las unidades motoras son irregulares la señal mencionada puede considerarse un proceso estocástico de banda limitada con una amplitud gaussiana [15]. De manera específica el EMG de superficie se registra mediante electrodos colocados sobre la piel y tiene un rango de frecuencias que se sitúa entre DC y los 500 Hz [16].

#### 2.4.3) Estados del EMG

Durante la contracción muscular se identifican dos fases o estados en la MES: el estado transitorio y el estado estacionario. El estado transitorio se presenta durante la ejecución de un movimiento, corresponde a los instantes de la ráfaga de actividad mioeléctrica que acompaña al esfuerzo muscular repentino. El estado estacionario se manifiesta durante una contracción donde no cambia la longitud del músculo, corresponde al periodo de tiempo durante el que se realiza tal esfuerzo muscular [17].



#### 2.4.4) Ruido en el EMG

En el registro y detección de las MES hay dos cuestiones de interés que influyen en la calidad de las señales:

- Relación señal a ruido
- Ruido de señal

En general el ruido es definido como señales eléctricas que no son parte de las MES deseadas [18]. La relación señal a ruido representa la proporción de energía de la MES respecto a la energía de las señales de ruido. La dificultad del análisis del EMG radica en la presencia del ruido en su registro [19] el cual puede ser disminuido utilizando la técnica apropiada, la cual depende del tipo de fuente de la interferencia. Este ruido puede provenir de distintas fuentes como las que se enlistan en el siguiente apartado.

##### 2.4.4.1) Tipos de ruido en la señal EMG

El ruido eléctrico que afecta la fidelidad de un EMG puede depender de algunos de los siguientes tipos de interferencias:

- Ruido inherente en equipo electrónico: Lo genera el equipo electrónico que trabaja en frecuencias que van desde los 0 Hz hasta los varios miles de Hertz [20]. Con instrumentación electrónica de alta calidad este ruido puede ser eliminado.
- Ruido ambiental: La fuente de este tipo de ruido es la radiación electromagnética y evitarlo no es aconsejable, ya que inclusive la superficie del cuerpo humano emite este tipo de radiación. Se considera también ruido ambiental la interferencia de la línea de alimentación que se origina de





fuentes de poder que trabajan a 60 Hz. El uso de filtros rechaza banda pueden remover este tipo de ruido.

- Artefactos de movimiento: Cuando la piel y los electrodos se mueven entre sí debido al cambio de la longitud de los músculos durante el movimiento se produce ruido usualmente en un rango de frecuencias desde 1 Hz hasta los 10 Hz [20]. También el movimiento de los cables de los electrodos puede producirlo. Usar una interfaz que promueva un contacto continuo entre la piel y los electrodos puede remover significativamente los artefactos de movimiento.
- Inestabilidad inherente de la señal: La tasa de disparo de las unidades motoras provocan la inestabilidad en los componentes de frecuencia entre 0 Hz y 20 Hz [20]. Debido a esta naturaleza inestable de estas componentes son consideradas como ruido. Se puede evitar su interferencia con el uso de filtros pasa altas.
- Artefactos electrocardiográficos: Es la actividad eléctrica del corazón que contamina el EMG, frecuentemente sucede en estudios electromiográficos de músculos del torso corporal. Debido a la similitud de características entre señales electrocardiográficas y electromiográficas como la superposición de sus espectros, la remoción de este tipo de artefactos puede ser posible con técnicas de análisis que permitan identificar distintas señales estadísticamente independientes [20].
- Diafonía: En la diafonía (usualmente conocida como “*crosstalk*”) parte de la MES de un grupo muscular no monitoreado contamina un EMG bajo observación [20]. Incrementar la superficie de contacto de los electrodos puede aumentar su espacio bipolar y su diferenciación matemática, por lo que aumentar el tamaño y la distancia entre electrodos (1-2 cm) puede reducir esta interferencia.



## 2.5) Reconocimiento de patrones

El reconocimiento de patrones es un área de la inteligencia artificial [21] que se encarga de la clasificación de objetos, personas, señales, etcétera. Se trabaja con base a un conjunto de todos los posibles objetos individuales a reconocer, generalmente llamados patrones.

En el esquema general de un sistema de reconocimiento de patrones de bioseñales, el sensor (múltiples electrodos en la electromiografía) tiene como propósito proporcionar información factible de los elementos a ser clasificados, es decir, se pretende obtener patrones de las propias bioseñales. Para eliminar la información redundante e irrelevante de las señales monitoreadas se usa la extracción de características. La extracción de características es la etapa que se encarga de obtener información que ayude a discriminar entre las diferentes clases a reconocer. Por último el clasificador es el módulo de toma de decisiones en el sistema. Cuando éste es entrenado su rol es encontrar los patrones de los objetos pertenecientes a la misma clase. Finalmente cuando el clasificador ya entrenado se utiliza su rol es asignar nuevos objetos (que no hayan sido usados en su entrenamiento) a su categoría (o clase) apropiada.

## 2.6) Aprendizaje supervisado

El aprendizaje supervisado es el entrenamiento de un modelo computacional para relacionar dos conjuntos de datos. En el reconocimiento de patrones donde se usa este tipo de aprendizaje los vectores de características de los valores de entrada (llamados observaciones) se asignan a valores de salida (llamados objetivos), con el fin de que este modelo clasificador prediga el valor de salida asignado a cada vector de características (Fig. 5).




Fig. 5. Esquema de aprendizaje supervisado en reconocimiento de patrones

La clasificación que usa el esquema de aprendizaje supervisado consta de varias etapas relacionadas entre sí, las cuales de modo general se pueden dividir en etapa de entrenamiento del modelo y etapa de aplicación del mismo.

Los valores de entrada son representados generalmente por vectores de características extraídos del análisis del EMG. Un clasificador de esquema de aprendizaje supervisado es capaz de identificar en vectores de características particularidades (patrones) que permitan asignar cada vector de características a una de las posibles clases (Fig. 6). En el control mioeléctrico las clases corresponden a diferentes comandos que son generados para manipular un actuador [1].

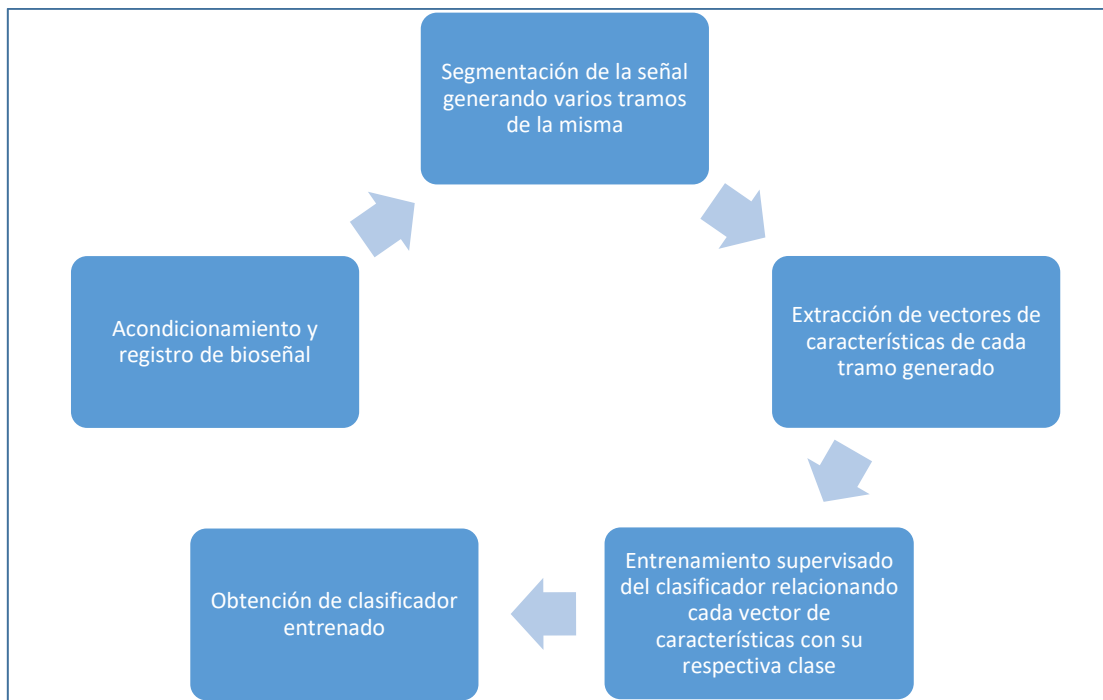


Fig. 6. Entrenamiento de un clasificador del esquema de aprendizaje supervisado



## 2.7) Características de MES

Las MES son por naturaleza estocásticas y generalmente se representan en vectores de características de pequeña dimensión con el fin de incrementar la exactitud que obtiene un modelo de clasificación supervisada basado en electromiografía. Muchos modelos clasificadores han demostrado obtener exactitudes mayores al 90% utilizando las características del llamado vector de características de Hudgins. Tres características frecuentemente usadas son: valor absoluto promedio, longitud de forma de onda y cruces por cero (MAV, WL y ZC respectivamente, por sus siglas en inglés) [22]. Incluso existen casos en los que no se usa la característica de cambios de signo de pendiente (SSC, por sus siglas en inglés) del vector de Hudgins porque no contribuye significativamente en el desempeño de un clasificador [23].

El MAV se calcula en cada segmento  $i$  de  $N$  muestras de la señal mediante la siguiente ecuación:

$$\bar{X}_i = \frac{1}{N} \sum_{k=1}^N |X_k|, \quad i = 1, 2, \dots, I \quad (2-1)$$

La WL provee información de la actividad de la onda de cada segmento analizado de la señal:

$$WL = \sum_{k=1}^N |\Delta X_k|, \quad \Delta X_k = X_k - X_{k-1} \quad (2-1)$$

Los ZC son una representación simple de la frecuencia de una señal, es el número de veces que la forma de onda cruza por cero como su nombre hace referencia:



$$ZC = ZC + 1 \quad \leftrightarrow \quad (X_k > 0 \cap X_{k+1} < 0) \cup (X_k < 0 \cap X_{k+1} > 0) \quad (2-2)$$

También es común combinar el uso de coeficientes autorregresivos (AR, por sus siglas en inglés) con las características de Hudgins [24]. Los coeficientes AR representan MES como series temporales autorregresivas lineales proporcionando información del estado de la contracción muscular. Se define como:

$$X_k = \sum_{i=1}^p a_i X_{k-i} + e_k, \quad (2-3)$$

donde  $a_i$  representa el coeficiente autorregresivo,  $p$  es el orden del modelo AR y  $e_k$  es el ruido blanco residual [25].

## 2.8) Características en el dominio tiempo-frecuencia

Las características en el dominio tiempo-frecuencia (TFD, por sus siglas en inglés) pueden caracterizar la variación de información de frecuencia en diferentes localizaciones temporales, proporcionando abundante información estadísticamente no estacionaria de las señales que se analicen con este tipo de características [19].

Las características en el TFD han sido utilizadas para la clasificación de señales EMG. Las más utilizadas son la transformada de Fourier de tiempo corto y la transformada Wavelet (STFT y WT respectivamente, por sus siglas en inglés). Utilizando la transformada de Fourier (FT, por sus siglas en inglés) puede ser obtenido el espectro de frecuencias de una señal estacionaria. Aunque el EMG no es estacionario por naturaleza, existen métodos como la STFT que realiza una segmentación en ventanas de dicha señal, lo cual permite considerar los segmentos resultantes como estacionarios, que son así determinados para poder analizarlos. Pero aunque es posible adaptar la señal como se mencionó para poder analizarse con la FT, esta tiene sus limitaciones, ya que no permite incrementar la resolución en el



dominio en el dominio del tiempo y de la frecuencia de forma simultánea. En cambio la WT supera esta deficiencia, otorgando en segmentos de análisis de gran longitud buena resolución en el dominio de la frecuencia aunque pobre en el dominio del tiempo; y viceversa, otorgando en segmentos de análisis de pequeña longitud buena resolución en el dominio del tiempo aunque pobre en el dominio de la frecuencia [26]. Debido a esta ventaja el análisis con WT se ha vuelto el método más común de procesamiento ya que éste es un análisis capaz de poder determinar el contenido frecuencial en períodos específicos.

El mayor problema de las características en el TFD es la alta dimensionalidad de los vectores de características resultantes [27]. Para evitar la complejidad de las características en el TFD, la reducción de dimensionalidad es implementada para reducir la cantidad de los datos mientras se mantiene e incluso mejora su capacidad de discriminación [28], [29]. Acorde a Englehart [30], hay dos estrategias para la reducción de dimensionalidad:

- Proyección de características
- Selección de características

Los métodos de proyección de características se realiza el mapeo de las mismas para formar un nuevo conjunto de características el cual es generalmente más pequeño que el original [31]. En la otra estrategia se elige el mejor subconjunto del vector de características original, de acuerdo a un criterio específico para poder juzgar si un subconjunto es mejor que otro [28].

En varios estudios con el fin de incrementar la exactitud y velocidad del entrenamiento del modelo clasificador se ha reportado otra estrategia para la reducción de dimensionalidad a través de la extracción de características directamente de los coeficientes de la transformada de Wavelet discreta [31–35].



## 2.9) Transformación de Wavelet discreta

La transformada Wavelet discreta (DWT, por sus siglas en inglés) permite representar una señal convirtiéndola en subconjuntos de coeficientes multirresolución. La DWT es computacionalmente más eficiente que la transformada Wavelet continua (CWT, por sus siglas en inglés), por lo que se ha vuelto la característica en el TFD más común en interfaces electromiográficas.

En el caso de la electromiografía de superficie, las funciones Wavelets que sirven para descomponer un EMG son elegidas generalmente aquellas cuyas formas sean similares al MUAP [37] como lo es la función Wavelet de la familia Daubechies 8 (Fig. 7).




Fig. 7 Wavelet ortogonal Daubechies 8

La DWT es una implementación de la WT usando un conjunto discreto de escalas Wavelet y traslaciones obedeciendo algunas reglas definidas. Es definida como:

$$DWT(m, n) = 2^{-\frac{m}{2}} \sum_k s(k) \psi(2^{-m}k - n) \quad (2-4)$$



El parámetro  $n$  es el factor de traslación que desplaza la función Wavelet a lo largo de la señal,  $m$  su factor de escalamiento,  $s(k)$  es la señal que se analiza y  $\psi_{m,n}(k)$  es la propia función Wavelet [38].

La función Wavelet puede ser construida del escalamiento de una función que describa ciertas propiedades. La restricción de que las funciones deben ser ortogonales en las traslaciones discretas, implica algunas condiciones matemáticas en ellas como la ecuación de dilatación:

$$\phi(x) = \sum_{k=-\infty}^{\infty} a_k \phi(Sx - k) \quad (2-5)$$

Donde  $S$  es un factor de escala (usualmente elegido como 2). Además, el área entre la función debe ser normalizada y la función de escala debe ser ortogonal a sus traslaciones enteras, como lo indica:

$$\int_{-\infty}^{\infty} \phi(x)\phi(x+l)dx \quad (2-6)$$

Después de introducir algunas condiciones más (es decir, como las restricciones recién mencionadas no producen una solución única) podemos obtener resultados de estas ecuaciones, o sea, el conjunto finito de coeficientes  $a_k$  que define la función escalada y también la función Wavelet. La función Wavelet es obtenida del escalamiento  $N$ , donde  $N$  es un entero. El conjunto de funciones Wavelet conforman entonces bases ortonormales, la cuales se usan para descomponer las señales que se analicen con esta transformación [39].

La DWT trabaja en dos distintas escalas al mismo tiempo (tiempo y frecuencia). De forma iterativa se utilizan filtros pasa altas y pasa bajas en la señal a transformar para obtener sus coeficientes Wavelet, donde cada vez se obtienen datos con mayor





resolución en frecuencia. El procedimiento de la descomposición multirresolución de una señal  $x[n]$  es mostrado esquemáticamente en la siguiente figura (Fig. 8).

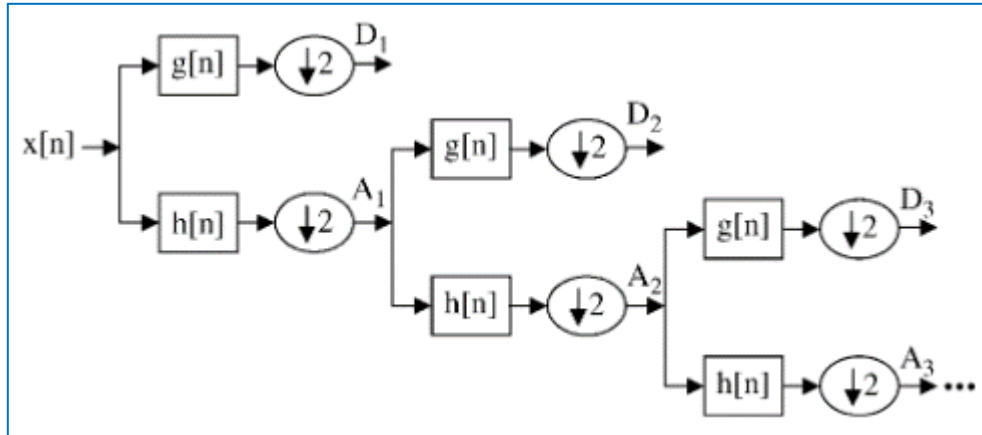


Fig. 8. Descomposición multirresolución con DWT [40]

Cada etapa de este esquema consiste en dos filtros digitales y dos decimaciones en un factor dos. Cada filtro  $g[\cdot]$  se comporta como un filtro pasa altas usando una versión escalada y desplazable de la llamada función Wavelet madre (o función Wavelet); contrariamente el filtro  $h[\cdot]$  se comporta como un filtro pasa bajas al usar la versión espejo de la función mencionada. Las salidas decimadas de los primeros filtros pasa altas y pasa bajas proveen los coeficientes de detalle  $D_1$  y de aproximación  $A_1$  respectivamente. Los primeros coeficientes de aproximación  $A_1$  también son descompuestos y este proceso continúa hasta el nivel de descomposición deseado [41]. Los coeficientes obtenidos representan la señal original en menor información y generalmente son considerados características que permiten conservar su comportamiento particular.

Las secuencias de aproximación y de detalle obtenidas como resultado de la DWT son de gran cantidad en términos de número de variables, lo cual contribuye a la larga dimensionalidad del espacio de características. Se usan técnicas de reducción de dimensionalidad como las mencionadas en el apartado anterior para que los vectores de características tengan el menor número de variables posible conservando su información particular, aumentando así la velocidad y la exactitud de un clasificador.



### 2.10) Longitud de ventana y estacionariedad

La estacionariedad es la propiedad que caracteriza que no cambien con el tiempo los parámetros estadísticos en un proceso estocástico como la MES. Una señal estacionariamente débil indica que sólo pocos parámetros estadísticos como la función de autocorrelación son invariantes en el tiempo [42].

Se han sugerido apropiados tamaños de ventanas en varios experimentos para asegurar la estacionariedad de la MES. Cabe señalar que las MES pueden ser no estacionarias durante la contracción dinámica debido a los cambios en la fuerza, la velocidad y la longitud del músculo [43]. La WT analiza señales estacionarias [44] y también puede estudiar señales no estacionarias [45]. Al asumir que una señal no es estacionaria la WT usa diferentes tamaños de ventanas para lograr un análisis multirresolución.

### 2.11) Red neuronal perceptrón multicapa

La red neuronal artificial (ANN, por sus siglas en inglés) es una máquina de aprendizaje automático que combina unidades de procesamiento elementales llamadas neuronas. Las ANN generalmente consisten en un conjunto de unidades de entrada, conectadas con varias capas de neuronas y una capa de salida. El objetivo de una ANN es ajustarse para lograr relacionar sus salidas con sus entradas, este proceso de ajuste se conoce como entrenamiento.

Cada una de las neuronas usadas tiene una función de activación (ej. lineal, logarítmica sigmoideal, tangente sigmoideal) para procesar su información y la función de activación más usada es la función de tangente hiperbólica (Fig. 9) debido a que produce una salida en el rango de -1 a +1 [46], es abreviada también como tansig y definida como en la ecuación ( 2-7 ).




Fig. 9. Función de activación tangente hiperbólica [46]

$$\tanh = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2-7)$$

La arquitectura de ANN más utilizada generalmente es la red neuronal perceptrón multicapa (MLPNN, por sus siglas en inglés) debido a rapidez de procesamiento y a su alta capacidad de generalización. Su ventaja respecto a otros métodos de aprendizaje es su capacidad de ajustarse a relaciones no lineales de las observaciones de entrada.

Las MLPNN se han utilizado principalmente en el campo del reconocimiento de patrones. Cada vector de características que representa una observación (un objeto a clasificar) es utilizado como entrada en una MLPNN y a cada uno de éstos le es asignado como salida un identificador (un vector o un escalar) que representa su pertenencia a una de las posibles clases del modelo, comúnmente llamado objetivo.

Cuando es entrenada de forma adecuada una MLPNN, ésta obtiene la capacidad de estimar correctamente la salida de entradas que no fueron usadas en su entrenamiento (capacidad de generalización).



A grandes rasgos una MLPNN se compone de:

1. Una capa de entrada con neuronas que representan las características variables de las observaciones.
2. Una capa de salida con neuronas que representan variables que permiten identificar la pertenencia de cada observación (Son las variables a las que se ajusta el método de aprendizaje).
3. Una o varias capas ocultas que ayudan a ajustar el modelo computacional a relaciones no lineales de los patrones.

En gran variedad de tareas de estimación como el reconocimiento de patrones la MLPNN es una arquitectura muy utilizada de las ANN [47]. En la siguiente figura se pueden apreciar la visualización gráfica de las relaciones entre las capas existentes en esta arquitectura (Fig. 10). Cada una de las relaciones tiene su respectivo peso  $W$ , todos éstos se optimizan durante el entrenamiento de la ANN para predecir correctamente las salidas asignadas a cada vector de características de entrada.

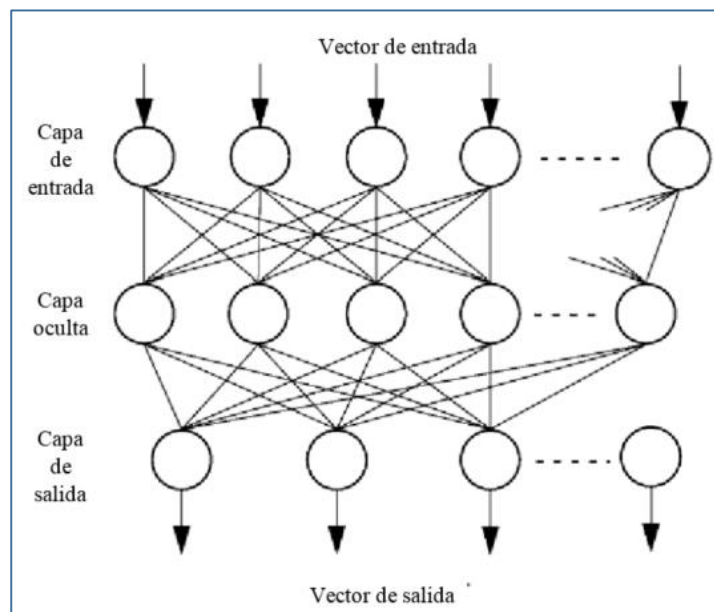


Fig. 10. Red neuronal perceptrón multicapa [48]



Esta optimización se puede realizar mediante diferentes métodos, aunque el más habitual es el de *back propagation* definido por ( 2-8 ) [49].

$$\delta_{jp} = f'(net_{jp}) \sum_i W_{ij} \delta_{ij} \quad (2-8)$$

Donde  $\delta$  es el ajuste aplicado a los pesos ( $\delta_{ij}$  representa el ajuste anterior y  $\delta_{jp}$  el ajuste posterior),  $f'(net)$  es el resultado de la ANN con los pesos actuales y  $W_{ij}$  son los pesos actuales [49].

### 2.12) Sensibilidad, especificidad y exactitud

La sensibilidad mide la frecuencia con la que se predice correctamente una determinada clase. En otras palabras, una sensibilidad de 1 significa que todas las instancias (observaciones) de la clase A fueron predichas como de la clase A. La ecuación ( 2-9 ) representa su cálculo donde  $TP$  son los verdaderos positivos de la clase  $x$ ,  $FN$  son los falsos negativos de la clase  $x$  y  $P$  representa la totalidad de los positivos.

$$Sensibilidad = \frac{TP}{P} = TP/(TP + FN) \quad (2-9)$$

La especificidad mide la frecuencia con la que se predice correctamente la no pertenencia a una clase. Es decir, se mide una especificidad de 1 si únicamente las instancias pertenecientes a la clase A son clasificadas como de la clase A. La ecuación ( 2-10 ) representa su cálculo donde  $TN$  son los verdaderos negativos de la clase  $x$ ,  $FP$  son los falsos positivos de la clase  $x$  y  $N$  representa la totalidad de los negativos (no correspondientes a dicha clase).



$$\text{Especificidad} = \frac{TN}{N} = TN/(FP + TN) \quad (2-10)$$

La exactitud da una evaluación general, desafortunadamente a menudo se reporta solo la exactitud en vez de calcular también tanto la sensibilidad como la especificidad de un modelo. La razón es que si la sensibilidad del modelo es alta (sobre 0.9) mientras la especificidad es baja (cercana a 0.3), la exactitud parecerá ser aceptable (sobre 0.6). La exactitud se calcula como lo indica la ecuación ( 2-11 ), cabe decir que si sólo se reportan la exactitud de un modelo, los resultados pueden parecer mejores de lo que son en realidad. Por ello siempre se deberían de calcular y reportar tanto la sensibilidad como la especificidad de los resultados de las pruebas [50].

$$\text{Exactitud} = (TP + TN)/(P + N) \quad (2-11)$$

### 2.13) Análisis inferencial

Son procedimientos estadísticos llamados “contraste de hipótesis” mediante los cuales se puede aceptar o rechazar una hipótesis nula ( $H_0$ ) y que automáticamente conlleva a rechazar o aceptar respectivamente una hipótesis alternativa ( $H_1$ ). La primera hipótesis postula la ausencia de diferencias estadísticamente significativas entre dos o más conjuntos de medidas (dando por hecho que las diferencias existentes se deben al azar), la segunda postula todo lo contrario, es decir, la existencia de diferencias estadísticamente significativas entre dos o más medidas.

En el contraste de hipótesis es relevante el nivel de significación o  $\alpha$  (rechazar una  $H_0$  cuando ésta es en realidad verdadera), así como el nivel de confianza ( $\alpha - 1$ ). Los valores habituales asumidos por los errores son el 10%, menos usado y, sobre todo 5% y 1%, siendo los niveles de confianza del 90%, 95% y 99% respectivamente [51].



### 2.14) Modelo virtual de extremidad superior

La conversión de cualquier sistema (real, conceptual, microscópico, cósmico, etc.) a un modelo virtual en tercera dimensión, facilita enormemente su visualización, y mejora la comprensión de su estructura y de su funcionamiento.

El uso de una prótesis virtual permite visualizar de inmediato si fueron correctamente predichas las observaciones de entrada en un modelo clasificador de movimientos articulares. Para demostrar visualmente la estimación realizada por el clasificador, se puede hacer uso de una prótesis virtual para reproducir los movimientos predichos a partir del procesamiento de señales, con el fin de mostrar visualmente la exactitud de un modelo clasificador [52] (Fig. 11).




Fig. 11. Modelo virtual de extremidad superior [52]



### 2.15) Estado del arte

El desarrollo en la detección de la intención de los movimientos articulares a través de sistemas de control mioeléctrico ha hecho posible el manejo de prótesis de forma natural. Dentro de las tendencias actuales en el reconocimiento de patrones a través de señales electromiográficas está el incremento del número de movimientos identificados, la reducción del número de canales de adquisición de los EMG y la discriminación de los movimientos en diferentes posiciones corporales [1].

Todos los tipos de prótesis tienen sus ventajas y desventajas en utilidad, costo, funcionalidad, apariencia y comodidad. Aunque las prótesis activas son generalmente las más utilizadas porque se enfocan principalmente en la sustitución de la funcionalidad natural de los miembros perdidos en vez de enfocarse en la apariencia, desafortunadamente son el tipo de prótesis más costosas y pesadas. Siendo las prótesis virtuales el tipo de prótesis más económicas debido a que no se requieren materializar físicamente, además son ideales para evitar el estrés causado por el elevado peso de las prótesis activas y sobre todo debido a que pueden evaluar rápidamente estrategias de control.

En las referencias consultadas se consideró el aporte de trabajos que abordaron el tema de control mioeléctrico de la extremidad superior y asimismo el de estudios relacionados con modelos virtuales también del miembro superior.

En el trabajo reportado por Nishikawa et. al [53], se identifican y controlan seis movimientos del antebrazo de los cuales cuatro son de interés para el proyecto (abrir-cerrar mano, flexión-extensión de la muñeca y pronación-supinación del antebrazo) con la utilización de sólo dos canales de electromiografía al nivel de la cintura escapular con un nivel de discriminación muy cercano al 90%.

En otro reporte [54] León presenta la identificación de siete movimientos de la mano usando dos canales electromiográficos. Su identificación se realiza tomando en cuenta





tres variantes de la posición anatómica de los sujetos de prueba, esto por considerarse un factor importante para la discriminación de los movimientos en diferentes posiciones corporales obteniendo porcentajes de clasificación de hasta 93%.

En un estudio Huang et al [55] demostraron que la combinación de coeficientes AR con características del dominio del tiempo como características para entrenar un clasificador disminuye el error de clasificación. Además comprueba que un postprocesamiento de las decisiones del sistema a través de una técnica de mayoría de votos ayuda significativamente para eliminar errores de clasificación falsos.

Un sistema electromiográfico proponen Chu et al [56] para el control de una mano virtual usando proyecciones de características como herramienta para reducir datos. Se usan cuatro canales electromiográficos en el antebrazo y el sistema identifica nueve movimientos de la mano con un 97% de clasificación correcta.

Un sistema de entrenamiento produce Barraza [52] para permitir la familiarización de personas amputadas con una prótesis de control mioeléctrica a través de una prótesis virtual. El usuario es capaz de manipular una interfaz visual con diferentes niveles de fuerza generados por la contracción de musculatura remanente de su muñón.

Un sistema capaz de identificar 27 movimientos del miembro superior es creado por León [2] con el objetivo de controlar tres grados de libertad simultáneamente para controlar un brazo antropomórfico virtual. Utiliza sólo cuatro canales electromiográficos para identificar siete movimientos simples y usa ocho canales para identificar 27 movimientos (7 movimientos simples, 12 combinaciones de 2 movimientos simples y 8 combinaciones de 3 movimientos simples). De cada observación se extraen características tanto en el dominio del tiempo como en el dominio de la frecuencia. Las observaciones mencionadas se clasifican con tres herramientas: ANN, análisis discriminante lineal y máquinas de soporte vectorial (LDA y SVM respectivamente, por sus siglas en inglés). Con SVM se reportan los mayores porcentajes porcentuales de



clasificación cuando se usan en conjunto con características del dominio de la frecuencia logrando un promedio de 95% de clasificación correcta.

Pla genera un sistema de clasificación de bajo costo computacional capaz de identificar movimientos musculares del estado transitorio de los EMG disminuyendo así el tiempo de predicción de los movimientos a través del uso de parámetros de Hjorth [57].

Se desarrolla un sistema capaz de combinar la información de sensores inerciales y magnéticos para estimar la posición y la orientación de un objeto arbitrario en un espacio 3D por Barraza [58]. Dicho sistema identifica la orientación del miembro superior con respecto al tronco del cuerpo sin importar la postura anatómica del usuario. Este sistema se representa en un modelo virtual. Los datos de dos empaquetados de sensores magnético-inerciales fueron utilizados para desarrollar un algoritmo que permite fusionar su información utilizando cuaterniones y matrices de rotación de cosenos directores.

Se utiliza las MES con la información de sensores inerciales para identificar con mayor precisión movimientos articulares del miembro superior en un trabajo desarrollado por Boschmann [3]. Para obtener un menor porcentaje de error de clasificación entrena su clasificador con información de los movimientos a distinguir pero en distintas posiciones de la extremidad superior. Esto comprobó una mayor confiabilidad de su sistema cuando se incluye información de sensores inerciales.

Blana evaluó un novedoso controlador de prótesis transhumeral que usa una combinación de señales cinemáticas y electromiográficas del húmero proximal para clasificar movimientos articulares. Usando un enfoque de clasificación jerárquica los datos que proporcionan los sensores cinemáticos en un primer modelo clasificador predicen la orientación de la extremidad superior y de forma subsecuente esa orientación es utilizada en un segundo modelo en conjunto con varias MES para finalmente clasificar los movimientos [59].



Del análisis anterior se aprecia la inclinación de las clasificaciones principalmente a incrementar el número de movimientos identificados y al hecho de poder hacerlo en posiciones corporales distintas. Aunque la mayoría de los trabajos de clasificación a través de electromiografía generalmente pasan por alto el reconocimiento de patrones en diferentes posiciones corporales los trabajos mencionados constatan la posibilidad de lograr predecir intenciones de movimientos en diferentes orientaciones del brazo. Además, basado en el estudio de Barraza [58] en este trabajo se propuso utilizar la orientación 3D que su sistema calcula como información adicional para poder referir las posiciones en las que se adquieran los EMG.

**La investigación del presente trabajo plantea como hipótesis que agregar el uso de la orientación de la extremidad superior a la clasificación de movimientos del antebrazo realizados en diferentes posiciones corporales incrementará significativamente la exactitud de un clasificador basado en electromiografía.**

La Tabla 1 muestra el aporte de algunos trabajos que son la base del presente estudio. En esta se puede apreciar que los estudios que se resumen son aquellos que usaron reconocimiento de patrones basado en electromiografía del miembro superior. Cabe agregar que en varios estudios de reconocimiento de patrones la medida de desempeño de sensibilidad, conocida como “tasa correcta”, es considerada como la exactitud [60]. Por esta razón todos los resultados que reportan exactitud en todos los trabajos de clasificación basados en electromiografía, representan en realidad las sensibilidades obtenidas en sus estudios [61], [62].



Tabla 1. Resumen de estudios de reconocimiento de patrones basados en EMG del estado del arte. S=Supinación, P=Pronación, F=Flexión de Codo, E=Extensión de Codo, C=Cierre de Mano, A=Apertura de Mano, M=Movimiento de Muñeca, CA=Combinaciones de los anteriores, y R=Reposo. Además SA= Saludable(s) y AM=Amputado(s).

Autores <sup>α</sup>	Año <sup>α</sup>	Nº-de-Canales <sup>¶</sup> N <sub>che</sub>	Nº-de-Movimientos <sup>¶</sup> N <sub>mo</sub>	Frecuencia-de-Muestreo <sup>α</sup>	N <sub>m</sub> /N <sub>che</sub>	Exactitud <sup>α</sup>	Número-de-Sujetos <sup>α</sup>
Nishikawa-et-al.[53] <sup>α</sup>	2001 <sup>α</sup>	2 <sup>α</sup>	6·(S++P++F++E++C++A) <sup>α</sup>	1,600-Hz <sup>α</sup>	3 <sup>α</sup>	79.3% <sup>α</sup>	1-SA-y-1-AM <sup>α</sup>
León-[54] <sup>α</sup>	2003 <sup>α</sup>	2 <sup>α</sup>	7·(S+P+C+A+2·M+R) <sup>α</sup>	2,048-Hz <sup>α</sup>	3.5 <sup>α</sup>	93% <sup>α</sup>	2-SA <sup>α</sup>
Huang-et-al.[55] <sup>α</sup>	2005 <sup>α</sup>	4 <sup>α</sup>	6·(2·M+S+P+C+A) <sup>α</sup>	1,000-Hz <sup>α</sup>	1.5 <sup>α</sup>	96.91% <sup>α</sup>	12-SA <sup>α</sup>
Chu-et-al.[56] <sup>α</sup>	2005 <sup>α</sup>	4 <sup>α</sup>	7·(4·M+C+A+R) <sup>α</sup>	1,024-Hz <sup>α</sup>	1.75 <sup>α</sup>	97.5% <sup>α</sup>	1-SA <sup>α</sup>
León-[2] <sup>α</sup>	2012 <sup>α</sup>	8 <sup>α</sup>	27·(6·(S+P+C+A+2·M)+20·CA+R) <sup>α</sup>	1,024-Hz <sup>α</sup>	3.37 <sup>α</sup>	95% <sup>α</sup>	20-SA <sup>α</sup>
Pla-[57] <sup>α</sup>	2014 <sup>α</sup>	8 <sup>α</sup>	6·(S+P+C+A+2·M) <sup>α</sup>	1,024-Hz <sup>α</sup>	0.75 <sup>α</sup>	89.96% <sup>α</sup>	21-SA <sup>α</sup>
Boschmann-et-al.[3] <sup>α</sup>	2013 <sup>α</sup>	4 <sup>α</sup>	8·(2·M+P+S+A+2·C+R) <sup>α</sup>	1,024-Hz <sup>α</sup>	2 <sup>α</sup>	95.5% <sup>α</sup>	2-SA <sup>α</sup>
Este-trabajo <sup>α</sup>	2018 <sup>α</sup>	2 <sup>α</sup>	12·(3·P+3·S+3·F+3·E) <sup>α</sup>	1,000-Hz <sup>α</sup>	6 <sup>α</sup>	55.41% <sup>α</sup>	10-SA <sup>α</sup>

Se ordenaron en la tabla anterior los estudios de electromiografía del estado del arte desde el más antiguo hasta el más reciente. Los datos de esta tabla serán abordados en el apartado de discusión de este estudio.



### 3) Desarrollo

#### 3.1) Solución Propuesta

En la siguiente figura (Fig. 12) se muestran las etapas propuestas para poder controlar el modelo virtual del miembro superior.

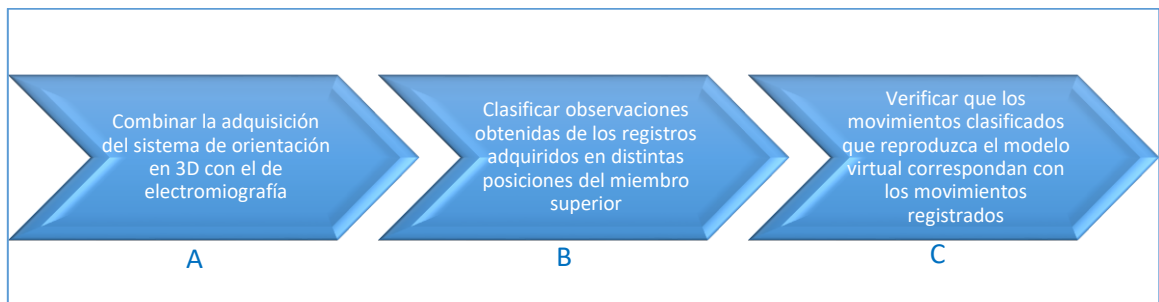


Fig. 12. Etapas de la solución propuesta

- A. Los registros se obtuvieron de las MES y del sistema de orientación en 3D desarrollado previamente [4]. Uno de los problemas fue la adaptación del equipo de adquisición electromiográfico para lograr sincronizar registros de electromiografía con los del sistema de orientación en 3D.
- B. Después, para clasificar los movimientos seleccionados en este estudio se extrajeron características del estado transitorio de las MES para poder incrementar la velocidad de predicción de sistemas basados en electromiografía al analizar sus señales en el segmento correspondiente a los primeros instantes de la contracción muscular. Posteriormente se clasificaron observaciones de entrada obtenidas de los movimientos mencionados a través de inteligencia artificial (reconocimiento de patrones).
- C. Finalmente se evaluaron las clasificaciones realizadas de los primeros instantes de los registros para probar el modelo desarrollado y se demostraron en un modelo virtual de la extremidad superior.



En la Fig. 13 se detalla mejor el proceso que se siguió en este estudio para desarrollar el modelo computacional que permite identificar movimientos de la extremidad superior.

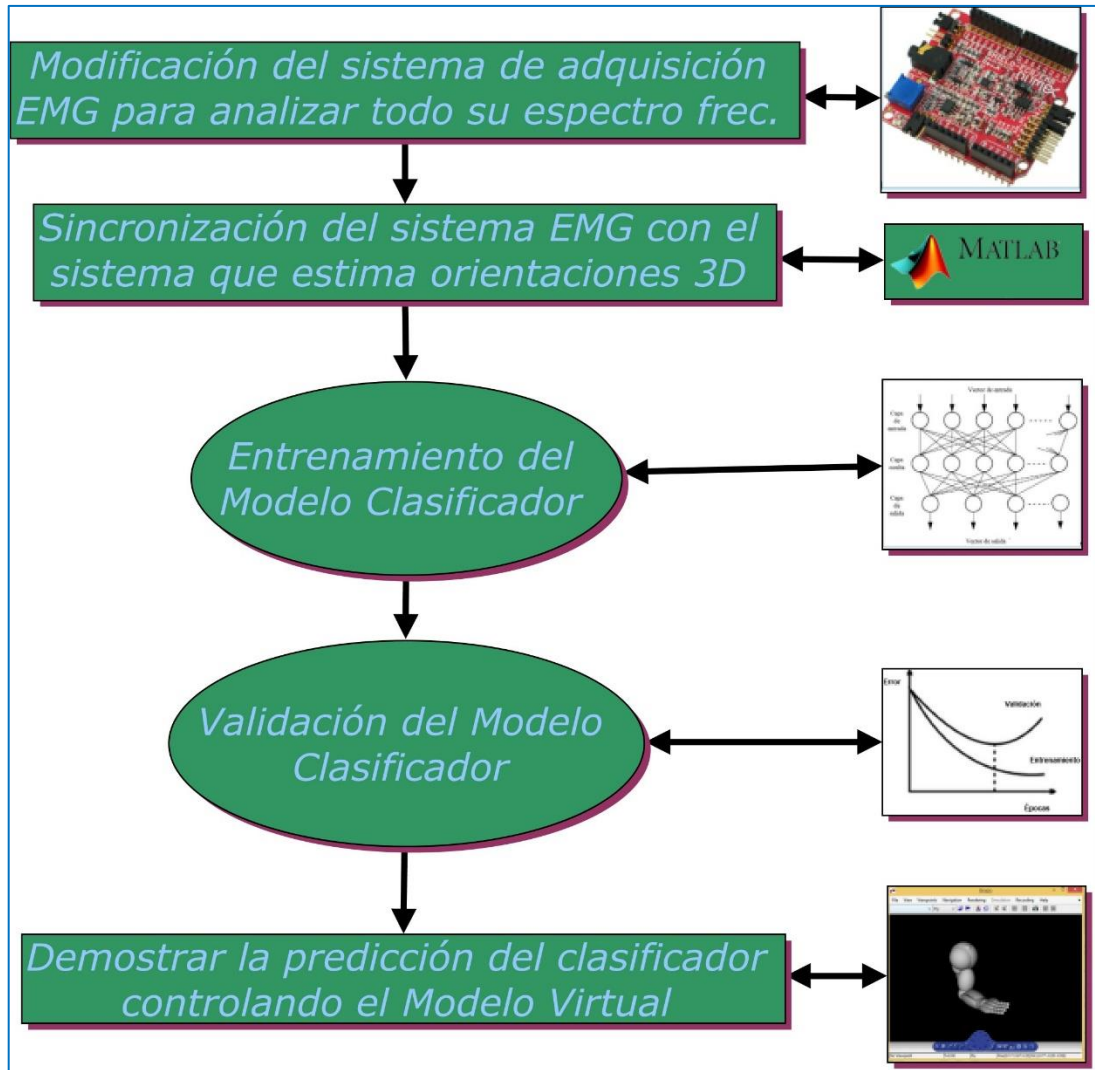


Fig. 13. Diagrama de bloques de la solución propuesta



Descripción de la solución propuesta:

1. Primeramente el sistema de adquisición de electromiografía se modificó para poder registrar todo el espectro frecuencial detectable con electromiografía de superficie.
2. Después se creó una interfaz en *MATLAB*® para registrar las MES mientras simultáneamente se registraba la orientación estimada de la extremidad superior, es decir, se sincronizó la adquisición de los EMG con la del sistema de monitoreo magneto inercial. Además, al mismo tiempo en el que se adquirían las señales se desplegaba un modelo virtual realizando el movimiento que el sujeto de prueba tenía que realizar durante cada registro.
3. Después se procesó la información obtenida de los registros segmentándolos en observaciones de entrada, extrayéndole a su vez a cada una su respectivo vector de características para entrenar el modelo computacional clasificador.
4. Cuando se obtuvo el modelo clasificador entrenado se validó su generalización probándolo con observaciones de entrada que no fueron usadas en su entrenamiento.
5. Finalmente, se demostraron en el modelo virtual las predicciones realizadas a partir de los primeros instantes de los registros de prueba hechas por el modelo computacional desarrollado.



### 3.2) Movimientos analizados

En este estudio se distinguen los movimientos de extensión y flexión del codo. Además, los movimientos que también se discriminaron fueron el de pronación y el de supinación, los cuales como se mencionó en el capítulo anterior son movimientos de rotación del antebrazo en torno a su eje longitudinal.

### 3.3) Posiciones corporales

En el presente trabajo se lograron clasificar los movimientos del antebrazo analizados en este estudio en las siguientes orientaciones del miembro superior [4]:

- P1. Con el brazo a 0° de flexión-extensión con respecto al plano sagital y a 0° abducción-aducción en el plano frontal (es decir, con la extremidad superior replegada a un costado del cuerpo).
- P2. Con el brazo a 90° de flexión anterior con respecto al plano coronal.
- P3. Con el brazo a 90° de abducción con respecto al plano sagital.

### 3.4) Músculos sensados

Los músculos elegidos para su monitoreo electromiográfico en la realización de los movimientos a reconocer fueron el bíceps braquial y el tríceps braquial. El bíceps cuando está flexionado presenta actividad muscular relacionada al movimiento de la supinación. Los electrodos del canal del bíceps se colocaron sobre la línea que generan el acromion medial y la fosa cubital; específicamente se colocaron a 1/3 de la longitud de dicha línea imaginaria desde la fosa cubital. Los electrodos del canal del tríceps se colocaron a la mitad de la distancia de la línea que generan la cresta posterior del acromion y el olécranon; específicamente a dos veces el ancho de un dedo de distancia de dicha línea imaginaria [63] (Fig. 14).






Fig. 14. Posición de los canales diferenciales del tríceps y del bíceps [64], [65]

La decisión de colocar los electrodos sobre el brazo fue tomada en base en no establecer la ubicación de los electrodos directamente sobre el segmento corporal en movimiento (el antebrazo) con miras a poder utilizar el método de clasificación del presente proyecto en aplicaciones con personas que tengan amputaciones por debajo codo en trabajos futuros.

### 3.5) Frecuencia de muestreo del sistema de adquisición de los EMG

Aunque la mayoría de las contribuciones de los MUAP no son incluidas en las MES de superficie [66] la morfología de estos potenciales es representada en el rango de altas frecuencias del espectro de potencia del EMG [67]. Por ello para casi todos los músculos y la mayoría de aplicaciones, el mayor armónico de interés en el EMG de superficie está en el rango de 400 a 450 Hz, por lo que se requirieron filtros pasa bajas (anti aliasing) con un corte en este rango (los cuales fueron de tipo activo y de primer orden) y un muestreo de al menos 1000 muestras por segundo [68] como se realizó en el presente trabajo, cumpliendo así el teorema de Nyquist.



### 3.6) Dispositivos utilizados para los registros

Este espacio se dedica a describir el material utilizado para adquirir y procesar la información obtenida.

#### 3.6.1) Equipo de cómputo para registro y procesamiento

Toda la experimentación incluyendo la adquisición de los registros, el despliegue del entrenamiento guiado por pantalla (SGT), el procesamiento de la información y la demostración en el modelo virtual fue llevada a cabo en una computadora LENOVO Y50-70 con sistema operativo Windows 8.1 (64-bit) con procesador *CORE* i7-4710HQ @ 2.5 GHz de Intel y 8 GB de *RAM*. Cada una de las etapas mencionadas fue codificada utilizando el lenguaje de programación *MATLAB*® R2013a de *MathWorks*. Se utilizó el programa *NCH Record Pad* para poder sincronizar a través de estímulos auditivos los registros adquiridos.

#### 3.6.2) Tarjeta *SHIELD-EKG-EMG* Olimex

La tarjeta *SHIELD-EKG-EMG* Olimex es un módulo creado para acoplarse directamente con tarjetas ARDUINO de Olimex aunque también es compatible con tarjetas de ARDUINO como ARDUINO UNO [69] (Fig. 15) .




Fig. 15. Tarjeta *SHIELD-EKG-EMG-Olimex* [70]

Permite la recolección de datos electrocardiográficos o electromiográficos a través de una serie de filtros que acondicionan la señal diferencial que envía a una de las entradas analógicas de la tarjeta a la que se acopla.

Debido a que cada una de estas tarjetas permite la adquisición solo de un canal de electromiografía se requirió el uso de dos de ellas para monitorear los dos músculos de interés.

### 3.6.3) **Electrodos *SHIELD-EKG-EMG-PA Olimex***

Son electrodos para adquirir electromiografía de superficie o electrocardiografía comercializados para la tarjeta *SHIELD-EKG-EMG Olimex* [71] (Fig. 16). Se compone de tres electrodos metálicos de superficie que tienen la propiedad de ser de fácil manipulación ya que al contrario de los electrodos desechables se puede cambiar su ubicación entre registros sin estropear su contacto con la piel.



Fig. 16. Electrodo *SHIELD-EMG-EKG-PA* Olimex [72]

#### 3.6.4) Modificación de las tarjetas *SHIELD-EMG-EKG* Olimex

Desafortunadamente, la banda de frecuencias de las tarjetas *SHIELD-EMG-EKG* Olimex está limitada con un filtro pasa altas que impide que señales que tienen información en frecuencias menores a 40 Hz sean obtenidas de forma íntegra, es decir, con todo su espectro frecuencial. Para permitir que la información de electromiografía superficial llegara íntegra se optó por modificar los filtros de cada tarjeta *Shield* de forma que se pudiera conservar la banda de frecuencias desde los 0.1 Hz hasta los 500 Hz.

Se realizó la modificación necesaria a dos tarjetas *SHIELD-EKG-EMG* Olimex para adquirir dos canales electromiográficos. En esta modificación se sustituyeron y retiraron algunos componentes del esquemático original de la tarjeta [69] (ver imagen en Anexo B). Las resistencias R14 y R15 fueron cambiadas por unas de valor de  $0 \Omega$  (con resistencia residual del orden de los  $1.5 m\Omega$ ); y la resistencia R18 fue sustituida



por una de 316  $\Omega$ . En la figura inferior (Fig. 17) se puede ver el esquemático resultante del filtro modificado.

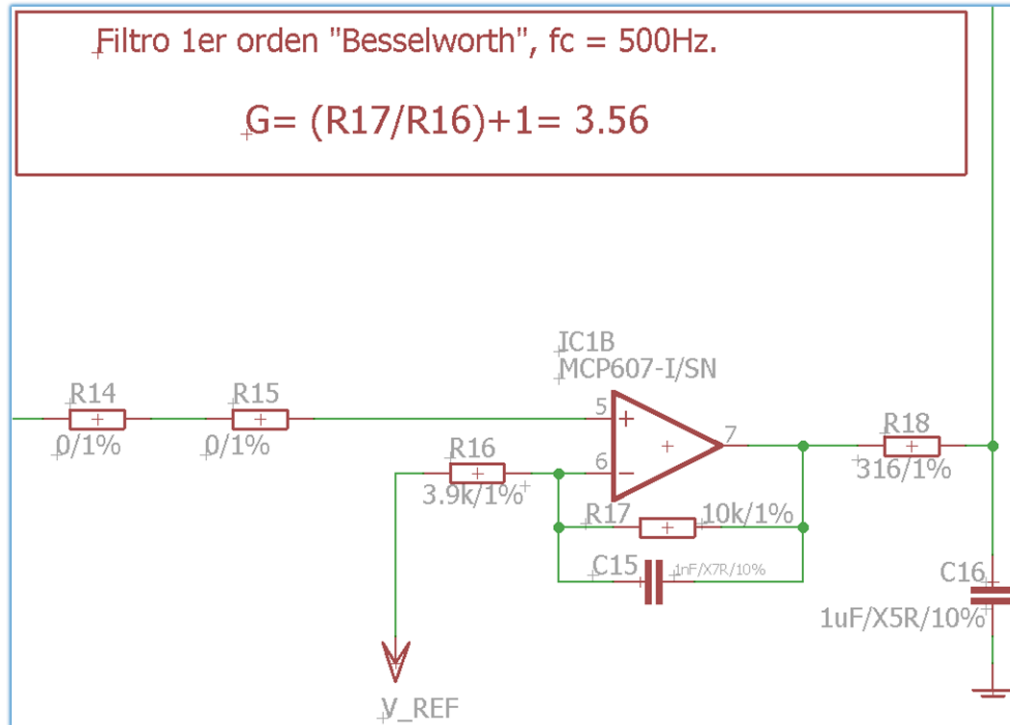


Fig. 17. Filtro acondicionador de señal modificado

En la figura del anexo A se pueden apreciar los espacios de los componentes donde se llevaron a cabo dichas modificaciones: Los componentes R14 y R15 se sustituyeron por resistencias de 0  $\Omega$  (rectángulos verdes) y la resistencia R18 por una de 316  $\Omega$  (rectángulo azul), además de retirar los capacitores C13 y C14 que formaban parte de un filtro activo tipo Sallen-Key de 2do orden (rectángulos negros).

La resistencia variable TR1 fue configurada con un valor de 0.775  $k\Omega$  lo que resultó en una  $G_2 = 57.338$  ya que la fórmula de dicha ganancia es calculada según la ecuación:



$$G_2 = \frac{100k}{1k + TR1} + 1 \quad (12)$$

### 3.6.5) Tarjeta de adquisición de los registros

Como se comentó previamente la tarjeta *SHIELD-EMG-EKG* Olimex requiere una tarjeta para digitalizar los datos que son acondicionados por el mismo. Viéndolo desde un punto de vista general el circuito de la tarjeta *Shield* sólo es una etapa de acondicionamiento analógico que se puede acoplar directamente con una tarjeta ARDUINO compatible [69] como lo es la tarjeta OLIMEXINO-328 de Olimex o la tarjeta ARDUINO UNO, de las cuales la última fue la utilizada en el presente proyecto.

La tarjeta ARDUINO UNO Rev 3 utilizada en este trabajo utiliza el microcontrolador ATmega328P, un cristal de 16 MHz, un conector de alimentación, una entrada ICSP (del inglés *In Chip Serial Programmer*), 14 salidas/entradas digitales y 6 entradas analógicas [73] (Fig. 18).




Fig. 18. Tarjeta ARDUINO UNO Rev 3 [73]



De las seis entradas analógicas de la tarjeta ARDUINO UNO Rev 3 dos de ellas se utilizaron para poder adquirir las dos señales mioeléctricas acondicionadas por las dos tarjetas *SHIELD-EKG-EMG* de Olimex. Cabe agregar que las cuatro entradas que no fueron utilizadas se conectaron a tierra para evitar interferencias y además en cada una de las dos entradas que sí fueron usadas se conectó a GND un capacitor cerámico de 100 nF para evitar ruido de alta frecuencia.

### 3.6.6) Fuente de alimentación para la tarjeta de adquisición

La alimentación recomendada de la tarjeta ARDUINO UNO Rev 3 es de 7 V – 12 V [73] por lo que para alimentarla se utilizó una batería de Ion-Litio 2UR18650Y de 1850 mAh marca PANASONIC [74] (Fig. 19)



Fig. 19. Empaquetado de batería 2UR18650Y de 1850 mAh [74]



### 3.6.7) Descripción del Sistema de orientación 3D

En el presente trabajo se usó un sistema de análisis de movimientos, el cual estima la posición y la orientación de la extremidad superior con respecto al torso [4]. Dicho sistema está compuesto por dos módulos de monitoreo y uno de comando. Los dos módulos de monitoreo estiman la orientación del tronco y de la extremidad superior respectivamente; el módulo de comando es configurado generalmente para fusionar la información de los módulos mencionados previamente para determinar la orientación relativa del módulo de monitoreo colocado en la mencionada extremidad superior con respecto a la orientación del módulo de monitoreo colocado en el tronco del cuerpo.

De forma general cada módulo de monitoreo contiene una unidad de seguimiento de 9 ejes *Invensense MPU-9150* con la cual se obtienen datos de la velocidad angular y aceleración del módulo y de la dirección del campo magnético terrestre. A través de su unidad de procesamiento (*Microchip®dsPIC-30F6014A*) los módulos de este sistema de orientación 3D desarrollado por Barraza [4] (Fig. 20) permiten calcular el cambio de orientación del módulo de monitoreo correspondiente al segmento corporal en análisis (el brazo) con respecto al segundo módulo de monitoreo perteneciente al torso (el cual sirve como sistema coordinado de referencia al primero).






Fig. 20. Módulos de monitoreo y de comando del sistema que estima la orientación [4]

En este estudio se obtiene la orientación de cada uno de los módulos de monitoreo. Ambas orientaciones son enviadas inalámbricamente al módulo de comando vía Bluetooth para ser posteriormente retransmitida por puerto serie a un programa creado en *MATLAB*®R2013. Este programa través de un producto de cuaternios estima y registra la orientación relativa del módulo de monitoreo localizado en la extremidad superior con respecto a la orientación del módulo de monitoreo localizado en el tronco corporal.

El presente proyecto usó la orientación estimada del brazo, como parte del vector de características de las observaciones de entrada del modelo clasificador de doce movimientos (cuatro movimientos en tres orientaciones espaciales distintas).

Cabe decir que ambos módulos de monitoreo estiman su orientación particular, pero la necesidad de obtener la orientación de la extremidad superior con respecto a un



sistema de referencia que es variable (el tronco corporal) derivó en el uso de ambos módulos en el presente proyecto. En resumen se obtuvo información de la orientación estimada de la extremidad superior por el sistema de Barraza para demostrar que su uso optimiza las predicciones realizadas por un modelo clasificador de movimientos articulares basado en las MES.

### 3.6.8) **Bandas elásticas sujetadoras**

Se utilizaron cinco bandas elásticas para poder conservar en su ubicación tanto a los módulos de monitoreo del sistema de orientación así como al sistema para adquirir los EMG. Cada una de las bandas elásticas integra velcro para ajustarse al segmento corporal que le corresponde rodear.

Se usó una banda elástica de 110 cm alrededor del tronco corporal (a la altura del mesogastrio) para poder colocar en ella el módulo de monitoreo del torso y el sistema para adquirir EMG. Cabe mencionar que dicho sistema para adquirir EMG fue asegurado a esta banda elástica a su vez con otra banda pero de una dimensión de 60 cm. Así también una segunda banda elástica de 60 cm abrazó la extremidad superior del sujeto de prueba y se colocó a la altura de la inserción del músculo deltoides para poder fijar a esta el módulo de monitoreo del brazo.

Los dos módulos de monitoreo se aseguraron a la banda elástica que se colocó en su respectivo sitio fijándolos a su vez a cada uno con una banda elástica de 30 cm. Se puede apreciar el tipo de bandas elásticas utilizadas en la siguiente imagen (Fig. 21).



Fig. 21. Tipo de banda elástica utilizada en el estudio

### 3.6.9) Acondicionamiento de brazaletes para los electrodos SHIELD EMG-EKG-PA Olimex

Para poder ajustar los brazaletes de cada electrodo de los electrodos *SHIELD-EMG-EKG-PA* Olimex a la circunferencia del brazo estos se modificaron agregándoseles una banda elástica de mayor longitud para que pudieran ajustarse a un diámetro de mayores dimensiones. Además para mejorar la fijación de cada brazalete a la extremidad superior se les agregó un pasacintos, evitando también así que colgara la parte de la banda elástica que no se utilizaba cuando la circunferencia a rodear del brazo no era de grandes dimensiones (Fig. 22).



Fig. 22. Brazaletes modificados con capacidad de rodear extremidades más voluminosas



### **3.7) Selección de características para las observaciones de entrada de la ANN**

En un esquema de aprendizaje supervisado para el reconocimiento de patrones, el componente más importante del diseño de una ANN es la elección de las características de sus observaciones de entrada, incluso el mejor clasificador tendrá un bajo desempeño si las mencionadas características no son bien seleccionadas. Las características elegidas tuvieron que involucrar tanto los registros de electromiografía como la información de la orientación de la extremidad superior.

#### **3.7.1) Características extraídas del sistema de orientación 3D**

Debido a que los cuaternios presentan la orientación estimada de los módulos de monitoreo [4] y al hecho de que se requiere tener el menor número de características que representen la información en el modelo clasificador para que su desempeño sea óptimo, se optó por convertir el cuaternio representante de la orientación estimada de la extremidad superior en ángulos Euler, disminuyendo así cuatro características de la orientación (una por cada componente del cuaternio) a sólo tres características, representando con esto los ángulos correspondientes a los ejes de alabeo, cabeceo y guiño.

Existen trabajos en donde se usan directamente los datos que proporcionan los sensores inerciales en un primer modelo clasificador para predecir la orientación de la extremidad superior y así de forma subsecuente usar la orientación predicha en un segundo modelo que clasifique movimientos musculares (generalmente llamada clasificación jerárquica) [75]. El presente trabajo disminuye el costo computacional de este tipo de modelos incorporando directamente la orientación estimada en ángulos Euler en vez de utilizar un sistema de clasificadores jerárquicos (consecutivos) como los trabajos del tipo mencionado.



### 3.7.2) Características extraídas del Sistema de electromiografía

Los coeficientes Wavelet discretos proveen una representación compacta de la distribución de la energía en tiempo y frecuencia. Por ello los coeficientes Wavelet discretos de aproximación y de detalle de segmentos (ventanas) de las MES fueron usados como vectores de características. Se realizó un ventaneo a cada señal de electromiografía con una longitud de ventana de 125 datos discretos. Los segmentos de señal fueron obtenidos desplazando la ventana cada 25 datos discretos. Cada ventana representó una observación de entrada para la MLPNN. Para cada segmento de EMG fueron calculados los coeficientes wavelet de detalle de los niveles primero, segundo, tercero y cuarto ( $D_k, k = 1,2,3,4$ ) y los coeficientes de aproximación del cuarto nivel ( $A_4$ ) [41]. Posteriormente se reconstruyeron cuatro ventanas ( $rec_i, k = 1,2,3,4$ ) por cada ventana analizada a partir de cuatro combinaciones diferentes de sus coeficientes Wavelet. Finalmente se calcularon y usaron siete características del dominio del tiempo de cada una de las cuatro ventanas de electromiografía reconstruidas, los ZC, la WL y el MAV y cuatro coeficientes AR, permitiendo obtener un total de 28 características por canal electromiográfico (Fig. 23). Debido a que en este estudio se usan dos canales se obtuvieron en total 56 características de la electromiografía por ventana de análisis.

$$\begin{aligned} rec_1 &= rec(D_1) + rec(A_4) \\ rec_2 &= rec(D_2) + rec(A_4) \\ rec_3 &= rec(D_3) + rec(A_4) \\ rec_4 &= rec(D_4) + rec(A_4) \end{aligned} \quad (4 AR + ZC + MAV + WL) / rec_i$$

Fig. 23. Representación de extracción de 7 características por cada ventana reconstruida

Posteriormente los parámetros de la MLPNN se optimizaron hasta lograr obtener la mayor exactitud con el modelo propuesto.



### 3.8) Adquisición con la tarjeta Shield de Olimex

La empresa Olimex desarrolló un programa de ejemplo de extensión INO que sirve de interfaz con el software *Electric Guru*, dicho programa a su vez funciona para transmitir datos desde la tarjeta de adquisición a la cual se acopla la tarjeta *SHIELD-EKG-EMG* Olimex. Fueron usados este programa y una librería que utiliza llamada "*FlexiTimer2.h*", la cual permite contabilizar segundos (s) de forma precisa, y se pueden descargar desde la página oficial de Olimex [70].

El programa mencionado al ser un software libre se permite su modificación. Se procuró adaptar sólo pequeños segmentos de código de este programa, para conservar su estructura original en medida de lo posible y así facilitar su lectura. El propósito de su adaptación fue comunicarlo vía puerto serie, con un programa que se desarrolló en este estudio, para permitir el registro de los datos que la tarjeta fuera transmitiendo.

En el programa ejemplo de Olimex se modificó la frecuencia de muestreo a 1000 Hz teniendo en cuenta que se requiere al menos una magnitud como tal para analizar en señales frecuencias menores o iguales a 500 Hz. En la trama de bytes que enviaba cada paquete de datos se usó la menor cantidad de información que permitiera conservar una frecuencia de muestreo de 1000 Hz. Cada paquete es compuesto por una trama de 13 bytes, usando en un byte como inicio de trama, un byte para contar los paquetes enviados, dos que indican el momento de su registro, ocho que representan la información electromiográfica y un último que sirve como byte de parada.

### 3.9) Entrenamiento guiado por pantalla

El entrenamiento guiado por pantalla (SGT) es una estrategia de preparación y adiestramiento utilizado en el campo de las prótesis para que su usuario pueda emular los movimientos que se le indican realizar con una guía visual desde un monitor. Esto



se realiza con el fin de que las instrucciones que se les soliciten a los usuarios, se ejecuten de una forma estandarizada, es decir, que todos los usuarios de la forma más semejante posible reproduzcan los movimientos procurando una velocidad similar de desplazamiento y las mismas posiciones articulares que las imágenes que se transmiten por la pantalla. En el presente trabajo se desarrolló un SGT basado en el modelo virtual de Barraza [52] para que sirviera de referencia a los sujetos de prueba mientras realizaban los registros de los EMG y de la orientación estimada de la extremidad superior (Fig. 24).



Fig. 24. Ejemplo del entrenamiento guiado por pantalla [76]

### 3.10) Protocolo de registros

Con el fin de poder reproducir en un modelo virtual creado en V-Realm Builder 2.0 [52] los movimientos registrados de la extremidad superior de una persona, se relacionaron segmentos de los EMG de su brazo derecho y también la información de la orientación 3D estimada del mismo con cuatro movimientos del antebrazo (flexión, extensión, pronación y supinación) en tres posiciones diferentes del miembro superior (doce clases de movimientos en total). Para poder estandarizar la adquisición de los



registros de todos los sujetos de prueba de la población de estudio se tuvieron en cuenta las particularidades que a continuación se describen.

El primero de los módulos de monitoreo se colocó en la región lateral del deltoides, a la altura de la inserción del músculo deltoides [77] (Fig. 25) y la colocación de los electrodos se realizó en la ubicación que fue descrita en el apartado 3.4) “Músculos Sensados”.

Debido al ruido que podría provocar una fuente de interferencia electromagnética como el de los equipos electrónicos, la sesión de registros se llevó a cabo en un lugar aislado de dispositivos e inclusive de fuentes de alimentación que pudieran inducir ruido en los EMG o desorientar el magnetómetro de los módulos de monitoreo.




Fig. 25. Región deltoidea lateral [78]

El segundo módulo de monitoreo se colocó entre la región umbilical y la región lateral izquierda del mesogastrio en el tronco corporal [79] (Fig. 26).





En un chasis de plástico se instaló el sistema de adquisición de EMG. Este último se colocó entre la región umbilical y la región lateral derecha del mesogastrio en el tronco corporal.




Fig. 26. Division topográfica del abdomen [79]

En la imagen de la Fig. 27, se puede apreciar la colocación de todo el equipo en un sujeto de prueba, donde se puede observar que tanto los módulos de monitoreo como



el equipo para adquirir los EMG se colocó en las regiones previamente mencionadas (Fig. 27).



Fig. 27. Fotografía de colocación de los dispositivos de adquisición

Se realizaron los registros con las especificaciones descritas a continuación. Como parte del protocolo experimental se realizaron los movimientos en tres orientaciones diferentes de la extremidad superior:

- P1. Con el brazo derecho recto replegado a un costado al cuerpo.
- P2. Con el hombro derecho realizando 90° de flexión anterior del brazo.
- P3. Con el hombro derecho realizando 90° de abducción del brazo.

El grupo de estudio se compuso de una mujer y nueve hombres de edades entre los 22 y los 31 años de edad. Los movimientos que realizaron los sujetos de prueba tienen las siguientes particularidades:



- a) El movimiento de pronación se ejecutó desde la posición de máxima supinación y viceversa, el movimiento de supinación se realizó desde la posición de máxima pronación.
- b) Los movimientos de pronación-supinación siempre se realizaron con 90° de flexión del codo en las tres posiciones de la extremidad superior que eran mantenidas mientras se ejecutaron en los movimientos.
- c) El movimiento de flexión se realizó desde una posición inicial donde los músculos involucrados en este movimiento conservan su tensión pasiva natural formando un ángulo entre el antebrazo y el brazo casi de 180° entre sí. El movimiento de extensión se realizó desde una posición inicial donde el codo se encuentre completamente flexionado.
- d) Cada movimiento de flexión se completó cuando alcanzaba la posición inicial del movimiento de extensión y viceversa, cada movimiento de extensión se completó cuando se alcanzaba la posición inicial del movimiento de flexión.

A cada uno de los sujetos de prueba se le efectuó su respectiva sesión de registros con los siguientes requerimientos:

- ✓ Cada uno de los movimientos se realizó cinco veces en cada orientación del hombro.
- ✓ La velocidad fue regulada a través la referencia visual de un SGT.
- ✓ Los estímulos auditivos indicaron el comienzo y la finalización de cada fase del registro.

Los estímulos auditivos emitidos por el programa para realizar los registros fueron grabados para poder utilizarlos como marcadores que determinan la localización del



inicio y el término del movimiento en los EMG, por lo que se requirió de un ambiente silencioso para evitar considerar algún ruido como marcador.

Cabe recalcar que la relación entre la información que se registró y los movimientos que efectuaron los sujetos de prueba se analizó especialmente durante las contracciones dinámicas de los músculos que son objeto de estudio, por ende para crear una base de registros con datos uniformes cada movimiento que fue realizado incorrectamente, en lo relativo a la velocidad del movimiento o la posición corporal, era repetido hasta que fuera reproducido satisfactoriamente.

### 3.11) Adquisición de la información de los EMG y de orientación 3D

Se identificaron los segmentos de las señales electromiográficas correspondientes a la ejecución del movimiento después de haber registrado simultáneamente de cada registro las MES (que fueron transmitidas vía comunicación serial a través de la tarjeta ARDUINO) y las orientaciones estimadas de los módulos de monitoreo de la extremidad superior (transmitidos vía comunicación serial a través del módulo de comando). Para hacer esto se sincronizó la ejecución de un programa de registro de audio llamado *NCH Record Pad* con la ejecución del programa creado en *MATLAB* para adquirir tanto EMG así como la orientación 3D estimada. De esta forma se pudo identificar el segmento de la señal comprendido entre los estímulos auditivos que marcaron el inicio y el término de la ejecución del movimiento. El siguiente esquema describe la adquisición de cada registro, donde cada vez que comenzaba o finalizaba una fase del movimiento *MATLAB* emitía un estímulo auditivo que sirvió como marcador en la señal EMG (Fig. 28).

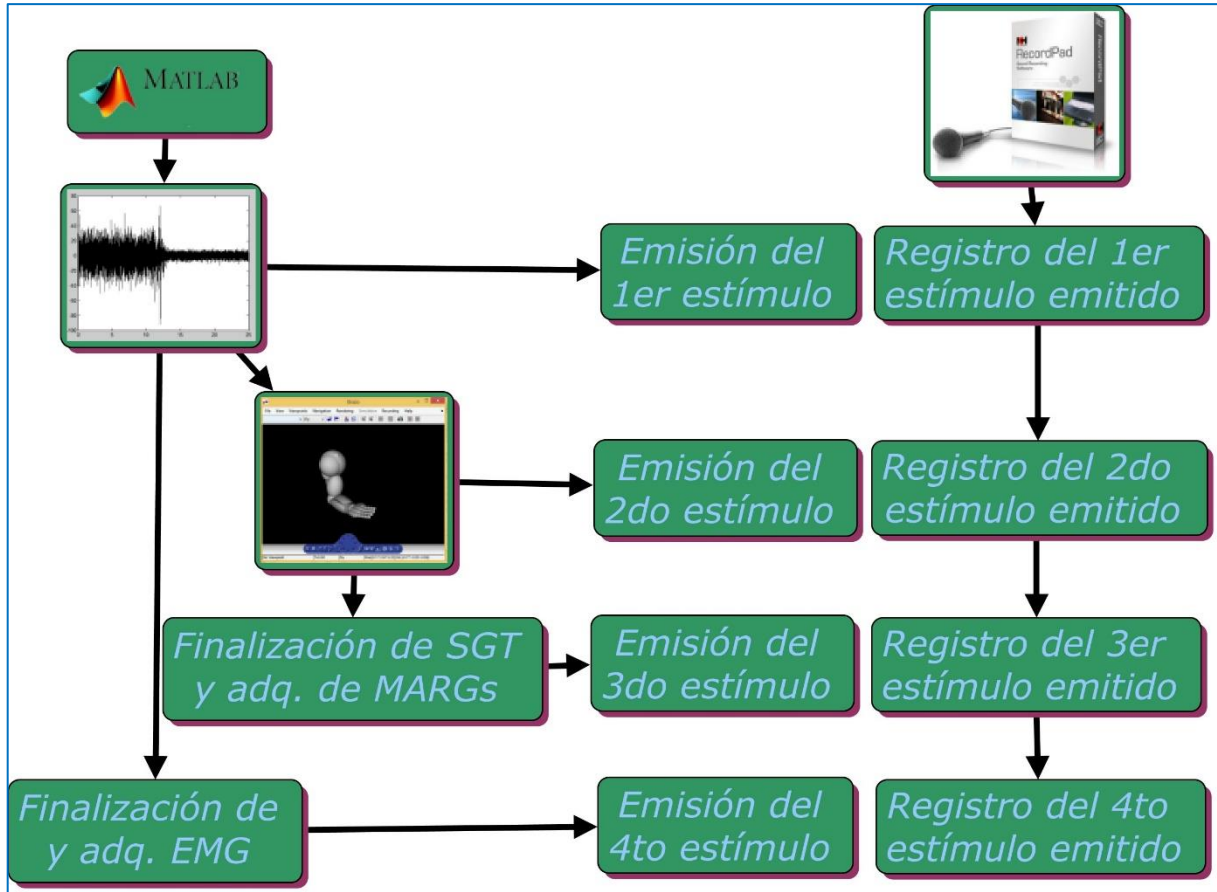


Fig. 28. Diagrama de secuencia de eventos durante un registro

Se creó un algoritmo que identifica los estímulos auditivos emitidos durante cada registro, automatizando su localización en el tiempo para utilizarlos como marcadores en los EMG para posteriormente separar y analizar el segmento de las señales correspondiente a la realización del movimiento (durante su contracción dinámica).

El primer marcador permitió identificar el inicio del registro electromiográfico, el segundo el inicio del movimiento y también el comienzo del registro de los módulos de monitoreo (y también la proyección del SGT en pantalla), el tercero el cese del propio movimiento y el cuarto la finalización del registro EMG.



### 3.12) Técnica de inteligencia artificial usada en el estudio

La clasificación supervisada a través del esquema de reconocimiento de patrones es el esquema de aprendizaje con el que se identificaron los movimientos articulares que se registraron. Las bioseñales de las que se extrajo la información fueron obtenidas de los canales electromiográficos localizados en el bíceps y el tríceps como se ha mencionado previamente. Cabe reiterar que esta información fue complementada con datos del sistema de posicionamiento y orientación 3D de la extremidad superior.

### 3.13) Procesamiento de los registros

Se eligió un par de EMG (del bíceps y del tríceps) de cada una de las doce diferentes clase de movimientos por sujeto de prueba para compararlas todas en conjunto (24 MES en total por cada sujeto de prueba). A cada EMG se le extrajeron sus coeficientes Wavelet discretos hasta el cuarto nivel de descomposición, a partir de estos coeficientes se reconstruyeron cuatro señales que fueron comparadas con su respectiva señal original. Esto se realizó de forma similar al apartado 3.7.2) pero en vez de reconstruir ventanas se reconstruyeron y compararon señales enteras. Las comparaciones se realizaron a través del cálculo de la conservación energética de las señales reconstruidas con el fin de averiguar cuáles funciones Wavelet utilizar en el procesamiento de las señales. Cabe agregar que las funciones Wavelet probadas para poder utilizarse fueron en total 80 de tres familias distintas y son descritas en el siguiente capítulo. La reconstrucción de las señales se realizó a partir de los coeficientes de aproximación del último nivel de descomposición en combinación con los coeficientes de detalle de cada uno de los cuatro niveles de descomposición Wavelet de forma independiente, obteniéndose así cuatro señales reconstruidas por cada señal original (una por cada nivel como se hizo en la sección 3.7.2)). Aquellas funciones de cada familia Wavelet que conservaron en la mayoría de las señales más energía fueron consideradas para utilizarse en este estudio.



Se sabe que el error de clasificación de movimientos basado en electromiografía depende de la longitud de las ventanas de análisis de los EMG. Debido a que un estudio demostró que la exactitud de clasificación incrementa cuando la longitud de los segmentos de análisis se encuentra entre 125 y 500 ms [80] y ya que la segmentación solapada es utilizada ampliamente con segmentos largos (mayores a 200 ms) para aumentar la velocidad de decisión de un sistema [81] se decidió utilizar ventanas de una longitud de 125 ms traslapadas cada 25 muestras, para poder así obtener una decisión mayoritaria en un tiempo menor de 300 ms, respetando con esto el retardo máximo que se supone aceptable para el control mioeléctrico de un dispositivo protésico [82] que requiere que el tiempo de análisis de las ventanas de los EMG y su procesamiento sea menor a este periodo.

Más tarde, se creó una MLPNN para relacionar a su correspondiente clase objetivo los vectores de características extraídos de las ventanas de los EMG y de la orientación 3D estimada. Posteriormente, se procedió a optimizar empíricamente el clasificador, es decir, se modificaron los hiperparámetros de la ANN con el fin de obtener un mejor desempeño en la clasificación de las ventanas pertenecientes al conjunto de observaciones de prueba del modelo.

A continuación, se clasificaron las ventanas de los primeros instantes de la ejecución del movimiento de los registros de prueba para identificar por decisión mayoritaria el tipo de movimiento articular al que pertenecen y por último estas predicciones se representaron en el modelo virtual de la extremidad superior.



## 4) Pruebas y resultados

En este apartado se reporta la experimentación y los resultados obtenidos de las pruebas realizadas en el presente proyecto. Los resultados se presentan en el orden de la metodología mencionada en el capítulo 3.

### 4.1) Verificación de ancho de banda del equipo de electromiografía

Se verificó la modificación que se realizó del ancho de banda del sistema de adquisición de electromiografía y se compararon los espectros de potencias del preamplificador original (la tarjeta *SHIELD EKG-EMG* Olimex) sin modificaciones y del preamplificador modificado.

Se calculó el espectro de potencia de dos EMG para poder comprobar la ampliación del ancho de banda de frecuencias de la modificación de la tarjeta *Shield* mencionada en el capítulo 3. Ambos EMG derivaron del mismo canal de adquisición electromiográfico, es decir, la misma señal fue filtrada tanto por la tarjeta *Shield* Olimex original y también fue filtrada por la tarjeta *Shield* Olimex modificada. Esto se logró realizar duplicando la MES con un cable divisor de señal de conector tipo Jack de 3.5 mm, que permite dividir la señal en dos terminales. En la imagen inferior se puede apreciar el cable diseñado para este propósito (Fig. 29).



Fig. 29. Cable divisor de señal de conector tipo Jack de 3.5 mm





Se generaron dos espectros en esta prueba, uno de la tarjeta *SHIELD-EKG-EMG* Olimex original sin modificación alguna y otro de la tarjeta *SHIELD-EKG-EMG* Olimex modificada. Se puede apreciar en la siguiente figura (Fig. 30) que la señal ADC0 corresponde a la tarjeta *Shield* original con su respectivo filtro pasa bajas de frecuencia de corte de 40 Hz y la ADC1 a la tarjeta *Shield* modificada con su ahora filtro pasa bajas de frecuencia de corte de 500 Hz. Se puede apreciar que el espectro de potencias de la señal ADC0 se convierte en un pico con colas que se extienden indefinidamente es evidentemente diferente al de la señal ADC1.

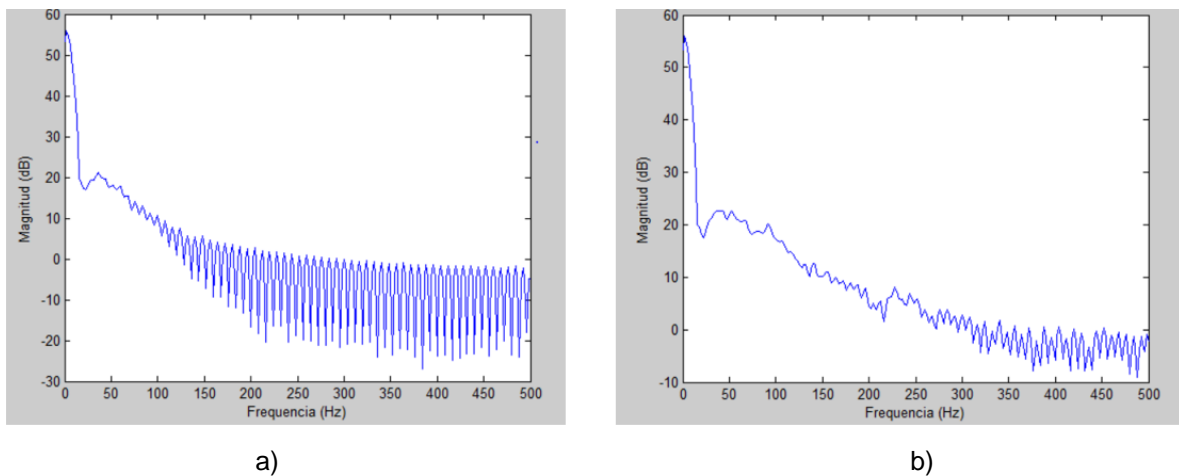


Fig. 30. Comportamiento del espectro de potencias. a) Señal ADC0 b) Señal ADC1

Se generó un tercer espectro de potencias para corroborar que el comportamiento del espectro de la señal ADC0 (de la tarjeta *Shield* original) es causado por el filtro de 40 Hz. Este tercer espectro correspondió a la señal ADC1 (de la tarjeta *Shield* modificado) pero filtrada digitalmente a 40 Hz (Butterworth 3er orden) (Fig. 31).

En esta prueba se puede apreciar que el espectro de potencias de la señal ADC0 es semejante al de la señal ADC1 filtrada digitalmente a 40 Hz, ambas presentan un pico con colas que comienzan a presentarse a partir de la frecuencia del filtro mencionado.

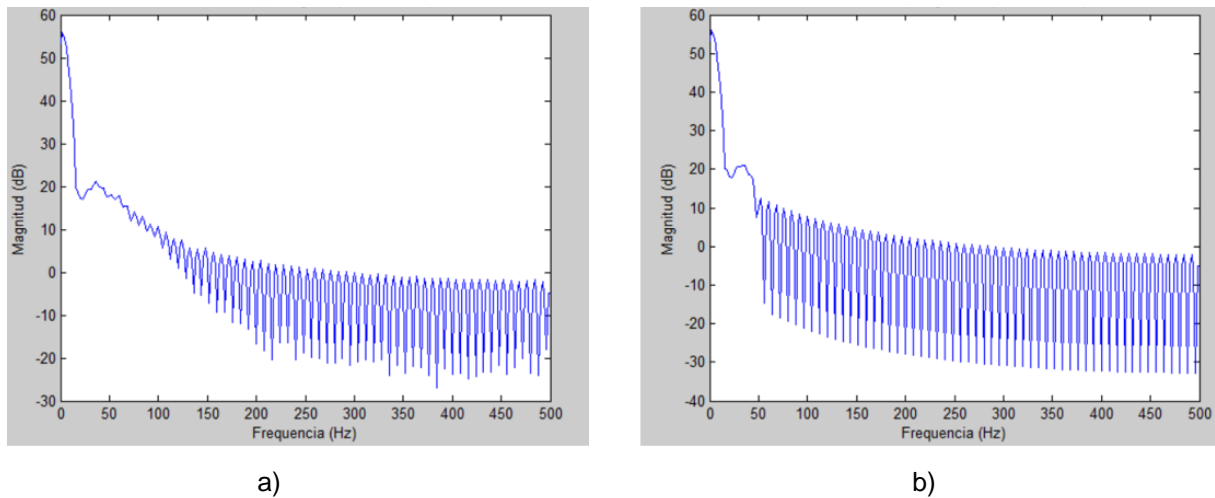


Fig. 31. Comportamiento del espectro de potencias. a) Señal ADC0 b) Señal ADC1 filtrada

Con el fin de eliminar artefactos de movimiento en los EMG deben bloquearse frecuencias menores de 10 Hz. Además para también disminuir la inestabilidad de la señal EMG se usó un filtro digital pasa altas de 15 Hz de tipo Butterworth en los registros electromiográficos. Finalmente el ancho de banda de los registros electromiográficos fue de 15 Hz – 500 Hz al implementar dicho filtro digital en las MES después de adquirirlas con el hardware.

#### 4.2) Validación cruzada *hold-out*

Se usó en este estudio la validación cruzada de tipo *hold-out* en la cual el conjunto de validación, que es un subconjunto de instancias (observaciones de entrada a clasificar o ventanas en nuestro caso particular) del conjunto de datos para entrenar el clasificador, evalúa el modelo durante su fase de entrenamiento para evitar el llamado “sobre entrenamiento”. Durante la mencionada fase de entrenamiento, cuando se comienza a presentar una tendencia de predicciones equivocadas en el conjunto de instancias de validación se permite detectar cuando el modelo empieza a sobre ajustarse a su conjunto de datos de entrenamiento, pudiendo provocar el mal funcionamiento del modelo con nuevos datos (es decir, nuevas instancias, observaciones o ventanas) disminuyendo su “generalización”.



La línea punteada de la Fig. 32 ejemplifica el instante cuando se detiene el entrenamiento para evitar el sobre entrenamiento.

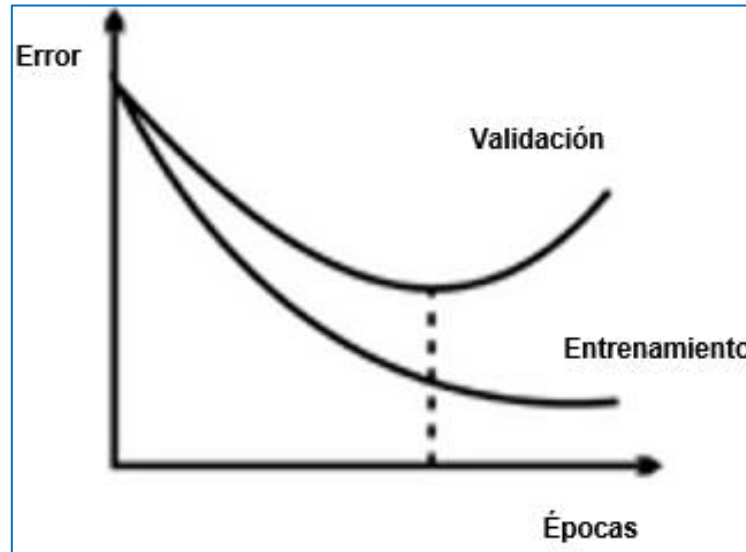


Fig. 32. Validación cruzada Hold-out [83]

### 4.3) Balance de los conjuntos de datos

En la fase de entrenamiento del clasificador, los subconjuntos de entrenamiento y de validación del modelo deben tener de cada una de las clases la misma proporción de instancias para optimizar la clasificación. Ejemplificando mejor lo anterior se dispuso que la proporción de los subconjuntos sea de 66.66% para el entrenamiento y de 33.33% para la validación, por lo que cada una de las doce clases fue dividida en la misma proporción: 66.66% de sus instancias para el subconjunto de entrenamiento y 33.33% de sus instancias para el subconjunto de validación. Estas proporciones de instancias, se tomaron del conjunto de instancias destinado a entrenar el clasificador.

### 4.4) Particionamiento de los datos

Usar los mismos datos para entrenar y probar un modelo puede producir resultados que aparenten tener una capacidad de generalización más alta de la que tiene en realidad. De este hecho se deriva la necesidad de contar con distintos conjuntos de



datos tanto para entrenar como para probar un modelo. La dificultad radica en la selección de los datos que integrarán cada uno de los conjuntos.

Para cada una de las doce clases se registraron cinco señales, obteniendo un total de 60 registros. La problemática radicó en saber cuáles de estas cinco señales entrenarán al modelo y cuáles lo probarán. Tres de estos cinco registros formaron parte de la etapa de entrenamiento y los dos restantes hicieron lo propio con la parte de la prueba del modelo. Como se mencionó en el apartado anterior de los datos que forman parte del entrenamiento 66.66% pertenecieron al subconjunto de entrenamiento, es decir dos señales de las tres que tienen asignadas, y 33.33% pertenecieron al subconjunto de validación. En resumen se tienen tres conjuntos en total: dos señales pertenecientes al subconjunto de entrenamiento, una señal perteneciente al subconjunto de validación y dos señales pertenecientes al conjunto de prueba del modelo.

Entonces, para cada sujeto de prueba se averiguó cuál sería la mejor combinación de señales que pueden conformar cada uno de los tres conjuntos detallados en el párrafo anterior (entrenamiento, validación y prueba). Con base en el método de prueba y error las cinco señales fueron intercambiando su pertenencia a los tres conjuntos. De forma sistemática se fueron usando diferentes combinaciones de las cinco señales en los tres conjuntos. Para cada sujeto de prueba finalmente se usó aquella combinación que permitió obtener una mayor exactitud promedio (de las doce clases) en la prueba del modelo. Por ejemplo, si particularmente para el sujeto de prueba 1 los datos de las señales 3 y 4 formando parte del conjunto de entrenamiento, los datos de la señal 1 formando parte del conjunto de validación y los de las señales 2 y 5 formando parte del conjunto de prueba ofrecían una exactitud promedio mayor que todas las demás combinaciones posibles, entonces dichas señales conservaron su pertenencia a tales conjuntos en el modelo del sujeto de prueba 1. Se tiene que tener presente que aunque el modelo clasificador que se usa en todos los sujetos de prueba es el mismo, cada uno de estos finalmente obtiene su propio modelo entrenado



con sus respectivos datos, obteniendo así en total en este estudio diez modelos, uno por cada uno de los sujetos que participaron en este estudio.

#### 4.5) Funciones de entrenamiento de la MLPNN

Como funciones de entrenamiento de la red se utilizaron:

- ✓ Retropropagación Levenberg-Marquardt (`trainlm`)
- ✓ Retropropagación resiliente (`trainrp`)
- ✓ Retropropagación de gradiente escalado conjugado (`trainscg`)

La función de entrenamiento `trainlm` fue elegida porque es el algoritmo de retropropagación más rápido del *toolbox* de redes neuronales de *MATLAB*, este algoritmo es usado por defecto en el entrenamiento supervisado en dicho *toolbox*. En modelos de reconocimiento de patrones, `trainscg` y `trainrp` son buenas elecciones. Sus requerimientos de memoria son relativamente pequeños y son mucho más rápidos que algoritmos de gradiente descendente [84].

#### 4.6) Selección de función Wavelet

Se comparó la preservación del contenido energético de señales reconstruidas a partir de coeficientes wavelet de distintas funciones Wavelet. Esto fue para poder seleccionar aquella función Wavelet que permite conservar mayor contenido energético para posteriormente usarla en el procesamiento de los EMG.

Para comparar la conservación del contenido energético se utilizó la siguiente ecuación [85]:



$$EN = \sum_{k=1}^N |x_k|^2 \quad (13)$$

Donde  $EN$  es la energía de la señal  $x$ . Se obtenía tanto el contenido energético de cada señal original como el de su señal reconstruida para calcular posteriormente la razón de la energía de la señal reconstruida entre la energía de la señal original.

Para representar características en tiempo y en frecuencia de la señal y al ser la DWT una herramienta para realizar análisis multirresolución, esta se usó extrayendo coeficientes hasta el cuarto nivel de descomposición. Cada nivel de descomposición representa un rango de frecuencias de la señal (Tabla 2).

Tabla 2. Rangos de frecuencia de cada subbanda obtenida por la DWT de una señal muestreada a 1000 Hz

<b>Banda</b>	<b>Rangos de frecuencia (Hz)</b>
<b>Señal</b>	15 - 500
$D_1$	250 - 500
$D_2$	125 - 250
$D_3$	62.5 - 125
$D_4$	31.25 - 62.5
$A_4$	15 - 31.25

Los coeficientes Wavelet de cada nivel de descomposición representan la correlación existente entre el segmento del EMG analizado con la versión escalada de la función Wavelet madre que corresponde a tal nivel de descomposición. La función



Wavelet madre se desplaza a lo largo del EMG generando así diferentes niveles de correlación en cada desplazamiento.

El proceso de búsqueda de las funciones Wavelet madre (funciones Wavelet) se realizó de forma iterativa calculando la conservación de la energía de cada señal original con sus señales reconstruidas con diferentes funciones Wavelet [86]. Esto se hizo a partir de las cuatro combinaciones de sus coeficientes Wavelet mencionadas en el capítulo 3 de este texto.

Se investigó la eficiencia de 80 wavelets madre de 3 familias Wavelet ortogonales diferentes:

- Daubechies (db1-db45)
- Symlet (sym2-sym31)
- Coiflet(coif1-coif5)

Aquellas funciones Wavelet que permitieron conservar mayor energía de las señales originales fueron consideradas para utilizarse en la descomposición Wavelet. Las funciones Wavelet madre que en los diferentes niveles de descomposición obtuvieron los mayores valores de forma mayoritaria fueron db3, sym6 y coif5 (Fig. 33) al analizar señales de diferente tipo de movimiento de los diez sujetos de prueba como se especifica en el capítulo 3.

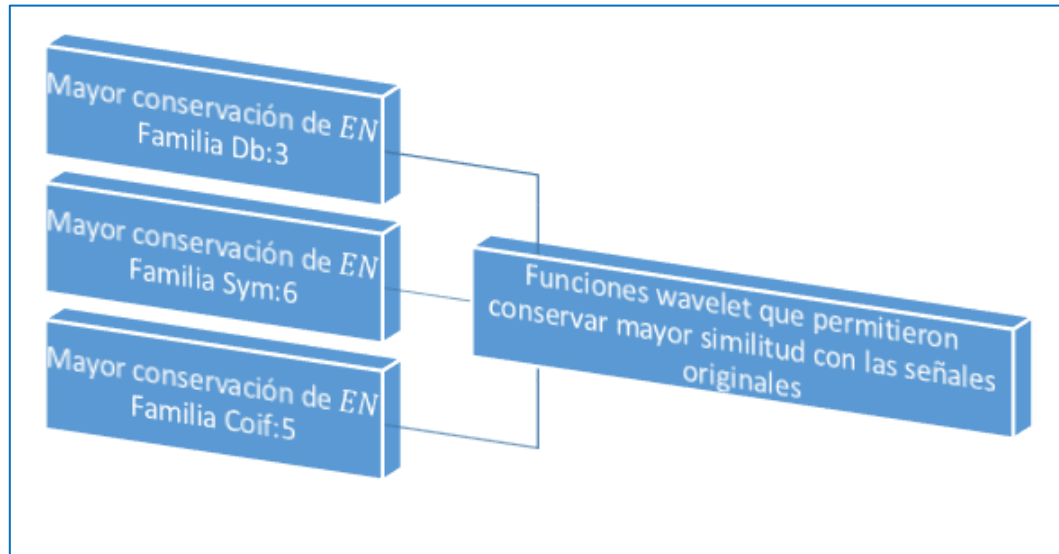


Fig. 33. Funciones Wavelets madre con mejor rendimiento

La función *coif5* coincidió como la función Wavelet madre que permite una reconstrucción de señal perfecta de acuerdo a un estudio realizado por Phinyomark en el 2009 [87], por lo cual finalmente esta función Wavelet fue elegida como la ideal para extraer los coeficientes wavelet en este estudio (Fig. 34).




Fig. 34 Función Wavelet Coiflet 5





#### 4.7) Características de las observaciones de entrada de la ANN

La selección de características de las observaciones de entrada del clasificador es el componente más importante en el diseño de una red neuronal basada en clasificación de patrones ya que incluso diseñando el mejor modelo clasificador su rendimiento será pobre si los vectores de características no fueron bien seleccionados.

Primeramente se obtuvieron los coeficientes de detalle y de aproximación de los EMG que corresponden a doce clases de movimientos (cuatro movimientos en tres orientaciones del brazo). El uso de dos canales de registro electromiográfico produce un número doble de coeficientes Wavelet para cada nivel de descomposición. Para crear un espacio de características multicanal (usando dos canales de registro o más) se pueden utilizar directamente los coeficientes Wavelet de los canales electromiográficos concatenando los coeficientes obtenidos del primer EMG con los obtenidos del segundo EMG y así consecutivamente [88]. Lamentablemente el problema estriba en no poder realizar un procesamiento con un número de características muy elevado. Es decir los coeficientes Wavelet que representan cada señal serían aproximadamente iguales al número de muestras analizadas por la DWT. Ejemplificando, como a las señales del presente trabajo se les aplicó DWT en segmentos de 125 muestras se obtendrían dependiendo de la función Wavelet madre utilizada aproximadamente 125 coeficientes por cada uno de los dos EMG. Entonces se hablaría de un total de 250 características por observación de entrada en el modelo clasificador, que si se usaran directamente el costo computacional sería muy elevado. Afortunadamente existen diferentes métodos de reducción de dimensionalidad que permiten mejorar el rendimiento de un clasificador como lo es el representar con características estadísticas la distribución tiempo – frecuencia de las subbandas de coeficientes de la DWT.

Se optó por extraer características del dominio del tiempo sobre cuatro ventanas reconstruidas a partir de cuatro combinaciones de los coeficientes de la DWT de cada EMG como se describe en el apartado 3.7.2). Las cuatro combinaciones de los



coeficientes de la DWT se hicieron a partir de la unión de los coeficientes de aproximación del último nivel de descomposición en conjunto con los coeficientes de detalle de cada nivel de descomposición ( $A_4$  y  $D_x$ ,  $x = 1,2,3,4$ ). A cada una de las cuatro ventanas reconstruidas se le extrajo WL, ZC, MAV y AR de cuarto orden [87]. Al modelo computacional como parte de las características de cada instancia (observación) de la MLPNN también se le incluyó la información de la orientación estimada del brazo expresada en los tres ángulos Euler, formando un vector de características de 59 elementos por cada ventana analizada, 56 pertenecientes a los EMG y tres a la orientación 3D calculada de la extremidad superior.

#### 4.8) Metodología del entrenamiento de la ANN

El clasificador fue configurado de tres formas diferentes al usar las tres funciones de entrenamiento seleccionadas en el apartado 4.5) (`trainlm`, `trainscg` y `trainrp`).

Es importante reiterar que se utilizaron dos de los cinco registros de cada clase para que sus instancias formaran parte del conjunto de prueba, el cual verifica el desempeño del modelo entrenado.

A partir del particionamiento de los datos de cada sujeto de prueba que haya permitido obtener la mayor exactitud de su propio modelo clasificador se optimizaron los parámetros de los tres algoritmos de entrenamiento como se detalla en el siguiente párrafo. Estos parámetros fueron ajustados empíricamente con el fin de incrementar la exactitud promedio de los diez sujetos de prueba.

Todas las funciones de entrenamiento usadas son código del *toolbox* de ANN de *MATLAB*. Para eliminar las tendencias en las instancias de entrada del modelo cada uno de los conjuntos de datos fue aleatorizado. La función de activación *tansig* fue usada en la capa oculta. El número de neuronas de la capa oculta se determinó calculando el promedio de neuronas de la capa de entrada con las neuronas de la capa de salida, de forma que si hipotéticamente se tienen dos neuronas en la de



entrada y cuatro en la de salida la cantidad de neuronas en la capa oculta sería de 3. Los vectores de entrada se normalizaron de -1 a 1 para que pudieran adaptarse al dominio de la función de activación *tansig*. La región de decisión de las neuronas de salida se optimizó redondeando a 1 los valores mayores de 0.55 y a cero los valores menores o iguales a 0.55. Los hiperparámetros que compartieron los tres algoritmos de entrenamiento fueron *max\_epochs*=1000, *performance goal*=0 y *min\_grad*=0.

Cada algoritmo de entrenamiento terminó optimizado con los siguientes hiperparámetros:

- Levenberg-Maquart: *max\_fail* = 6; *mu* = 1; *mu\_dec* = 0.7; *mu\_inc* = 1.5
- Gradiente Conjugado: *max\_fail* = 5; *sigma* = 5e-7; *lambda* = 5e-9;  
*performFcn* = 'mse';
- Retrop. Resiliente: *max\_fail* = 5; *lr* = 0.005; *delt\_inc* = 1.2; *delt\_dec* = 0.4;  
*delta0* = 0.07; *deltamax* = 50.0;

#### 4.9) Métodos estadísticos

Se implementó un análisis estadístico para encontrar diferencias significativas en el desempeño de tres clasificadores entrenados con sus respectivos algoritmos de entrenamiento. Se usó una prueba Friedman, el equivalente no paramétrico de la prueba ANOVA, debido a que se requiere usar una prueba estadística para muestras dependientes, que permita diferenciar grupos derivados de aplicarle diferentes “tratamientos” (algoritmos de entrenamiento) a los mismos datos [89]. Sus valores *p* fueron calculados configurando un 5% de error, estableciendo así cuando la hipótesis nula era rechazada ( $p < 0.05$ ). Para encontrar diferencias entre el clasificador que usa la orientación estimada del brazo y el clasificador que no la utiliza, la configuración del 5% de error también fue configurada en una prueba *t* de Student. Se usó esta prueba estadística porque puede comparar la diferencia entre dos conjuntos de poblaciones



de datos con distribución normal, pruebas como ANOVA sólo se pueden utilizar para comparar medias de tres o más grupos.

#### 4.10) Verificación de los modelos con el conjunto de prueba

En una clasificación multiclase se realiza el cálculo de los verdaderos positivos y negativos, y el de los falsos positivos y negativos, con un recuento por clase. Por ejemplo si se calcula la sensibilidad de la clase “setosa”, de la base de datos “iris” de la que se puede disponer desde *MATLAB* fácilmente, se trata “iris” como la clase positiva y todas las demás clases como negativas [86].

A cada una de las clases se les asignó su respectiva abreviatura para identificarlas con facilidad en los resultados (Tabla 3), cabe decir que las abreviaturas P1, P2 y P3 son las posiciones que fueron descritas en el protocolo de registros y en la sección 3.3) “Posiciones Corporales”.

Tabla 3. Abreviaturas de cada clase

Abreviatura	Clase
Flx0	Flexión de codo a 0° de abducción y de flexión del brazo (P1)
Flx90	Flexión de codo a 90° de flexión anterior del brazo (P2)
FlxAbd	Flexión de codo a 90° de abducción del brazo (P3)
Ext0	Extensión de codo a 0° de abducción y de flexión del brazo (P1)
Ext90	Extensión de codo a 90° de flexión anterior del brazo (P2)
ExtAbd	Extensión de codo a 90° de abducción del brazo (P3)
Sup0	Supinación a 0° de abducción y de flexión del brazo (P1)
Sup90	Supinación a 90° de flexión anterior del brazo (P2)
SupAbd	Supinación a 90° de abducción del brazo (P3)
Pro0	Pronación a 0° de abducción y de flexión del brazo (P1)
Pro90	Pronación a 90° de flexión anterior del brazo (P2)
ProAbd	Pronación a 90° de abducción del brazo (P3)



Con la premisa de las clasificaciones multiclase ejemplificada con la base de datos “iris” en el primer párrafo de esta sección a continuación se presentan en las siguientes tablas el promedio (Prom) y la variabilidad (desviación estándar muestral [ $\sigma$ ]) de la sensibilidad (Sens), la especificidad (Espec) y la exactitud (Exac) de los diez sujetos de prueba por cada uno de los modelos entrenados con los algoritmos de entrenamiento trainlm, trainscg y trainrp (Tabla 4, Tabla 5 y Tabla 6, respectivamente).

Tabla 4. Resultados de las pruebas con los registros de los 10 sujetos de prueba usando el modelo clasificador entrenado con el algoritmo Levenberg-Maquart usando ángulos Euler

Clase	Sens (Prom)	Sens ( $\sigma$ )	Espec (Prom)	Espec ( $\sigma$ )	Exac (Prom)	Exac ( $\sigma$ )
Flx0	0.80	$\pm 0.24$	0.98	$\pm 0.02$	0.97	$\pm 0.03$
Flx90	0.76	$\pm 0.21$	0.97	$\pm 0.02$	0.96	$\pm 0.04$
FlxAbd	0.67	$\pm 0.30$	0.96	$\pm 0.02$	0.94	$\pm 0.04$
Ext0	0.88	$\pm 0.18$	0.97	$\pm 0.02$	0.96	$\pm 0.03$
Ext90	0.51	$\pm 0.25$	0.99	$\pm 0.02$	0.95	$\pm 0.04$
ExtAbd	0.77	$\pm 0.24$	0.97	$\pm 0.03$	0.96	$\pm 0.04$
Sup0	0.66	$\pm 0.28$	0.98	$\pm 0.02$	0.96	$\pm 0.03$
Sup90	0.64	$\pm 0.33$	0.95	$\pm 0.03$	0.92	$\pm 0.04$
SupAbd	0.66	$\pm 0.23$	0.97	$\pm 0.03$	0.95	$\pm 0.03$
Pro0	0.65	$\pm 0.33$	0.97	$\pm 0.03$	0.95	$\pm 0.05$
Pro90	0.55	$\pm 0.36$	0.98	$\pm 0.04$	0.94	$\pm 0.05$
ProAbd	0.66	$\pm 0.33$	0.98	$\pm 0.02$	0.95	$\pm 0.03$



Tabla 5. Resultados de las pruebas con los registros de los 10 sujetos de prueba usando del modelo clasificador entrenado con el algoritmo de retropropagación del gradiente escalado conjugado usando ángulos Euler

Clase	Sens (Prom)	Sens ( $\sigma$ )	Espec (Prom)	Espec ( $\sigma$ )	Exac (Prom)	Exac ( $\sigma$ )
Flx0	0.65	$\pm 0.24$	0.95	$\pm 0.03$	0.93	$\pm 0.03$
Flx90	0.58	$\pm 0.28$	0.94	$\pm 0.05$	0.90	$\pm 0.06$
FlxAbd	0.46	$\pm 0.27$	0.93	$\pm 0.05$	0.89	$\pm 0.05$
Ext0	0.68	$\pm 0.26$	0.96	$\pm 0.04$	0.94	$\pm 0.05$
Ext90	0.40	$\pm 0.31$	0.98	$\pm 0.03$	0.93	$\pm 0.04$
ExtAbd	0.54	$\pm 0.22$	0.95	$\pm 0.04$	0.92	$\pm 0.06$
Sup0	0.12	$\pm 0.13$	0.98	$\pm 0.01$	0.91	$\pm 0.01$
Sup90	0.54	$\pm 0.26$	0.92	$\pm 0.02$	0.89	$\pm 0.02$
SupAbd	0.37	$\pm 0.28$	0.93	$\pm 0.05$	0.88	$\pm 0.05$
Pro0	0.20	$\pm 0.21$	0.95	$\pm 0.03$	0.89	$\pm 0.04$
Pro90	0.30	$\pm 0.33$	0.97	$\pm 0.02$	0.92	$\pm 0.03$
ProAbd	0.25	$\pm 0.16$	0.97	$\pm 0.02$	0.91	$\pm 0.02$



Tabla 6. Resultados de las pruebas con los registros de los 10 sujetos de prueba usando del modelo clasificador entrenado con el algoritmo de retropropagación resiliente usando ángulos Euler

Clase	Sens (Prom)	Sens ( $\sigma$ )	Espec (Prom)	Espec ( $\sigma$ )	Exac (Prom)	Exac ( $\sigma$ )
Flx0	0.65	$\pm 0.24$	0.95	$\pm 0.03$	0.93	$\pm 0.04$
Flx90	0.55	$\pm 0.26$	0.95	$\pm 0.04$	0.91	$\pm 0.05$
FlxAbd	0.41	$\pm 0.18$	0.93	$\pm 0.03$	0.89	$\pm 0.04$
Ext0	0.73	$\pm 0.22$	0.97	$\pm 0.02$	0.95	$\pm 0.03$
Ext90	0.46	$\pm 0.34$	0.97	$\pm 0.03$	0.93	$\pm 0.05$
ExtAbd	0.59	$\pm 0.19$	0.97	$\pm 0.03$	0.93	$\pm 0.03$
Sup0	0.26	$\pm 0.14$	0.98	$\pm 0.01$	0.92	$\pm 0.02$
Sup90	0.45	$\pm 0.27$	0.92	$\pm 0.04$	0.88	$\pm 0.05$
SupAbd	0.38	$\pm 0.27$	0.94	$\pm 0.04$	0.90	$\pm 0.04$
Pro0	0.27	$\pm 0.23$	0.95	$\pm 0.02$	0.90	$\pm 0.03$
Pro90	0.30	$\pm 0.28$	0.97	$\pm 0.03$	0.91	$\pm 0.04$
ProAbd	0.31	$\pm 0.20$	0.97	$\pm 0.02$	0.92	$\pm 0.02$

Para detallar los cálculos obtenidos de las tablas, en la figura inferior se ilustran los cálculos realizados de la sensibilidad y de la especificidad (Fig. 35). Para calcular el desempeño de un clasificador los resultados de sus pruebas usualmente son tabulados en una llamada matriz de confusión, que se aludirá como matriz Z. Esta matriz cuenta cuantas muestras (instancias, observaciones, ventanas) que son realmente pertenecientes a una determinada clase (filas) fueron predichas como pertenecientes a cada una de las diferentes clases (columnas). En otras palabras, una muestra perteneciente a la clase R y predicha como perteneciente a la clase P, es



contabilizada en  $Z_{R,P}$ . Las proporciones calculadas a partir de la matriz de confusión resumen el desempeño del clasificador [90]. En sus incisos b) y c) la Fig. 35 ejemplifica como calcular la sensibilidad y la especificidad con una matriz de confusión multiclase.

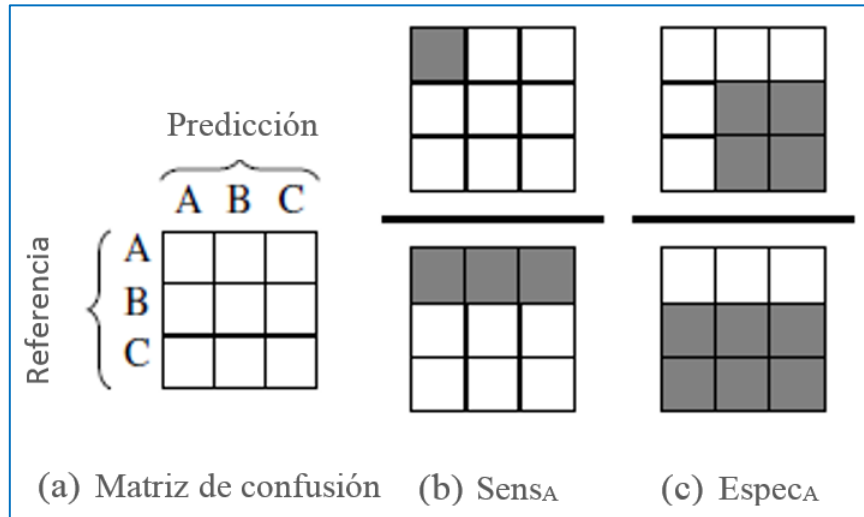


Fig. 35. Matriz de confusión y representación gráfica del cálculo de la sensibilidad y especificidad de su clase A [90]

Los valores obtenidos (Sens, Espec y Exac) de los diez sujetos de prueba fueron promediados y asimismo la respectiva desviación estándar de estos valores también fue calculada ( $\sigma$ ).

Se implementó la prueba de Friedman para comprobar si existen diferencias significativas entre los valores de los conjuntos de los tres de algoritmos de entrenamiento usados. Para permitir su distinción se usaron los datos de sensibilidad ya que estos aparentaron tener diferencias entre los tres conjuntos de datos. En el diagrama inferior (Fig. 36) se logra apreciar una diferencia entre el promedio de las clases del algoritmo trainlm en contraste con las promedios de los otros dos conjuntos de datos.

Se comparó después la información obtenida con la prueba Friedman para comprobar la nulidad de la hipótesis nula entre los conjuntos que tienen una media (promedio) distante.



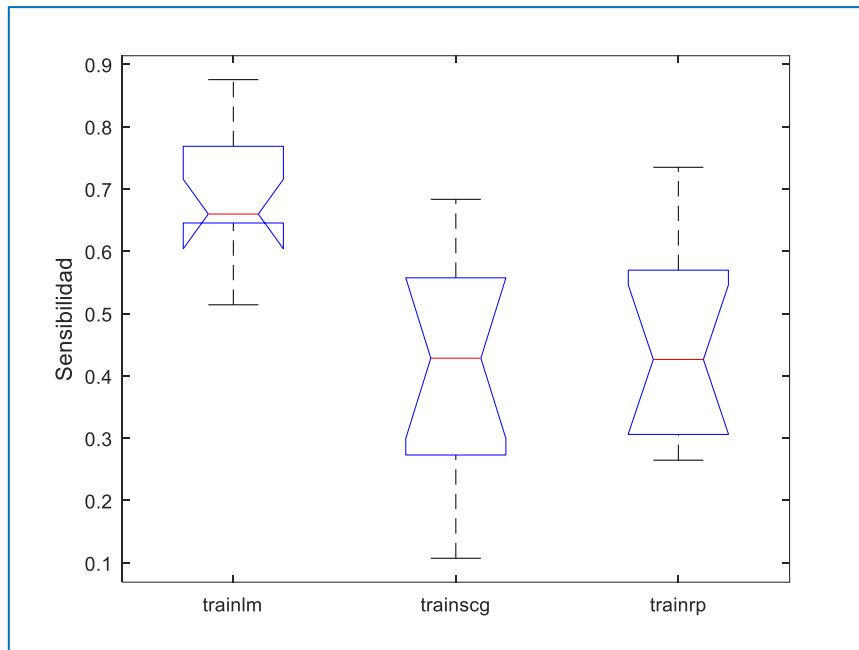


Fig. 36. Diferencia entre las sensibilidades con diferentes algoritmos de entrenamiento

En la Tabla 7 se puede apreciar que en las comparaciones que involucran el conjunto *trainlm* los valores de la cuarta columna correspondientes a la diferencia entre las medias de los grupos se encuentran dentro de sus intervalos de confianza del 95% (limitado por los valores de la tercer y la quinta columna) y sus valores *p* son cercanos a cero, lo cual comprueba que la hipótesis alternativa de que los conjuntos tienen diferencias significativas con dicho algoritmo de entrenamiento.

Tabla 7. Tabla para comparar los datos entre los modelos entrenados con diferentes algoritmos de entrenamiento

Comparación	A	B	Lim inferior	Dif	Lim superior	<i>p</i>
1	'trainlm'	'trainscg'	0.79	1.75	2.71	0.0001
2	'trainlm'	'trainrp'	0.29	1.25	2.21	0.0062
3	'trainscg'	'trainrp'	-0.46	-0.50	0.46	0.4385

Respecto a la comparación 3, se puede apreciar que ya que la diferencia de los grupos se encuentra fuera de su intervalo de confianza y a que su valor *p* es lejano a



ceros se acepta la hipótesis nula de que ambos conjuntos de valores son estadísticamente similares.

#### 4.11) Comparación de resultados sin el uso de la orientación 3D

Se procedió a realizar una comparación entre el modelo entrenado con el algoritmo Levenberg-Maquart, debido a que demostró tener mayores resultados de sensibilidad en el apartado anterior, utilizando ángulos Euler y sin utilizar ángulos Euler (Tabla 8) (Fig. 37).

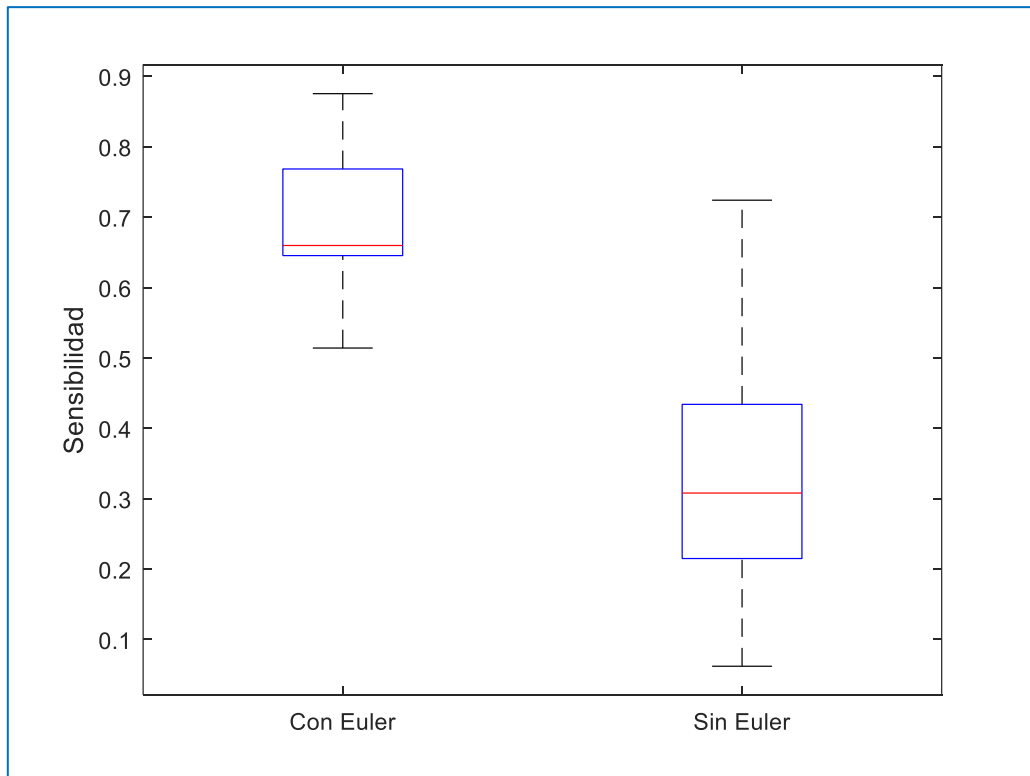


Fig. 37. Diagrama de caja del modelo trainlm con y sin grados Euler



Tabla 8. Resultados de las pruebas del modelo clasificador entrenado con el algoritmo Levenberg-Maquart sin ángulos Euler de los 10 sujetos de prueba

Clase	Sens (Prom)	Sens ( $\sigma$ )	Espec (Prom)	Espec ( $\sigma$ )	Exac (Prom)	Exac ( $\sigma$ )
Flx0	0.43	$\pm 0.21$	0.92	$\pm 0.03$	0.88	$\pm 0.04$
Flx90	0.44	$\pm 0.21$	0.92	$\pm 0.04$	0.88	$\pm 0.04$
FlxAbd	0.26	$\pm 0.24$	0.90	$\pm 0.04$	0.85	$\pm 0.03$
Ext0	0.72	$\pm 0.22$	0.94	$\pm 0.03$	0.92	$\pm 0.04$
Ext90	0.29	$\pm 0.16$	0.97	$\pm 0.02$	0.92	$\pm 0.03$
ExtAbd	0.46	$\pm 0.20$	0.97	$\pm 0.03$	0.92	$\pm 0.04$
Sup0	0.06	$\pm 0.06$	0.99	$\pm 0.01$	0.91	$\pm 0.01$
Sup90	0.41	$\pm 0.23$	0.90	$\pm 0.03$	0.86	$\pm 0.02$
SupAbd	0.33	$\pm 0.19$	0.93	$\pm 0.04$	0.88	$\pm 0.03$
Pro0	0.26	$\pm 0.15$	0.94	$\pm 0.03$	0.89	$\pm 0.03$
Pro90	0.17	$\pm 0.12$	0.97	$\pm 0.02$	0.90	$\pm 0.01$
ProAbd	0.17	$\pm 0.11$	0.98	$\pm 0.01$	0.91	$\pm 0.01$

Se usó la prueba estadística  $t$  de Student con un nivel de confianza del 95% y se obtuvo un valor  $p = 7.0822e - 07$  de este cálculo, lo que sugiere el rechazo de la hipótesis nula y comprueba que sí existe una diferencia significativa entre el modelo que usa los ángulos Euler con el que no los utiliza.



#### 4.12) Demostración de clasificaciones a través del modelo virtual

Para demostrar finalmente la validez del modelo se utilizaron dos señales de prueba por clase de cada sujeto de prueba para controlar el modelo virtual y así poder comprobar que el modelo computacional tuviera un desempeño aceptable, que además permitiera averiguar si se puede tener una predicción (o decisión) correcta en un tiempo menor o igual al máximo retardo permitido de 300 ms recomendado en prótesis electrónicas. Se analizó la porción de los EMG correspondiente a los 2 s que duró la ejecución de cada movimiento. Para esto se predijo una salida para cada una de las primeras ventanas de la señal, donde cada 25 ms se obtenía la predicción de una ventana diferente. Una decisión mayoritaria se tomaba después de recopilar 6 predicciones pertenecientes a una misma clase, considerándose dicha clase como la correspondiente al registro. Cuando se predecía la clase perteneciente del registro con este método inmediatamente se representaba en el modelo virtual el movimiento predicho. De forma contraria a lo que se creía normalmente se tenían que analizar más de 9 ventanas para tomar una decisión mayoritaria lo que producía que la clasificación del movimiento tardara regularmente más de 350 ms.

Las decisiones tomadas se registraron obteniéndose así la sensibilidad, especificidad y exactitud de los movimientos que representó el modelo virtual, posteriormente se promediaron los valores de todos los sujetos de prueba para representar el comportamiento general del modelo computacional desarrollado en este trabajo. Estos resultados pueden apreciarse en la Tabla 9 y se continuará su discusión en el siguiente capítulo de este estudio.

La mitad de los doce movimientos resultaron tener una sensibilidad menor a 0.5. El movimiento que obtuvo la sensibilidad más baja fue el de extensión a 90° posiblemente debido a que es mínimo el momento de fuerza que produce el tríceps cuando el brazo está flexionado a 90° para producir este movimiento. Los movimientos restantes tienen un nivel de sensibilidad que incrementa la probabilidad de identificarlos correctamente.



Tabla 9. Resultados de la validación del modelo computacional en el modelo virtual de los 10 sujetos de prueba

Clase	Sens (Prom)	Sens ( $\sigma$ )	Espec (Prom)	Espec ( $\sigma$ )	Exac (Prom)	Exac ( $\sigma$ )
Flx0	0.80	$\pm 0.35$	0.98	$\pm 0.04$	0.96	$\pm 0.04$
Flx90	0.45	$\pm 0.44$	0.98	$\pm 0.04$	0.93	$\pm 0.05$
FlxAbd	0.50	$\pm 0.47$	0.96	$\pm 0.05$	0.93	$\pm 0.06$
Ext0	1.00	$\pm 0.00$	0.95	$\pm 0.06$	0.96	$\pm 0.05$
Ext90	0.30	$\pm 0.35$	0.99	$\pm 0.01$	0.94	$\pm 0.03$
ExtAbd	0.35	$\pm 0.41$	0.96	$\pm 0.05$	0.91	$\pm 0.04$
Sup0	0.45	$\pm 0.50$	0.99	$\pm 0.02$	0.95	$\pm 0.04$
Sup90	0.75	$\pm 0.26$	0.92	$\pm 0.09$	0.91	$\pm 0.08$
SupAbd	0.75	$\pm 0.35$	0.91	$\pm 0.07$	0.90	$\pm 0.07$
Pro0	0.40	$\pm 0.51$	0.96	$\pm 0.05$	0.91	$\pm 0.07$
Pro90	0.35	$\pm 0.41$	0.97	$\pm 0.04$	0.92	$\pm 0.04$
ProAbd	0.55	$\pm 0.44$	0.92	$\pm 0.09$	0.89	$\pm 0.07$

La Tabla 9 muestra el desempeño de la validación del clasificador. Para detallar su realización a través de la Tabla 10 se pueden ejemplificar los cálculos de la sensibilidad, la especificidad y de la exactitud, respecto de la clase Flx0 del sujeto de prueba n° 10.



Tabla 10. Matriz de confusión del sujeto n° 10. Respecto a la clase Flx0 la celda sombreada de verde representa sus verdaderos positivos (TP), aquellas sombreadas de azul son sus falsos positivos (FP), las sombreadas de color naranja sus falsos negativos (FN) y las sombreadas de rojo sus verdaderos negativos (TN)

		Predicción											
		Flx0	Flx90	FlxAbd	Ext0	Ext90	ExtAbd	Sup0	Sup90	SupAbd	Pro0	Pro90	ProAbd
Referencia	Flx0	2	0	0	0	0	0	0	0	0	0	0	0
	Flx90	0	0	0	0	0	0	0	0	0	0	1	1
	FlxAbd	0	0	2	0	0	0	0	0	0	0	0	0
	Ext0	0	0	0	2	0	0	0	0	0	0	0	0
	Ext90	0	0	0	0	1	0	0	0	0	0	1	0
	ExtAbd	0	0	0	0	0	2	0	0	0	0	0	0
	Sup0	0	0	0	0	0	0	2	0	0	0	0	0
	Sup90	0	0	1	0	0	0	0	1	0	0	0	0
	SupAbd	0	0	0	0	0	0	0	0	2	0	0	0
	Pro0	0	0	0	0	0	0	0	0	0	2	0	0
	Pro90	0	0	0	0	0	0	0	0	0	0	2	0
	ProAbd	0	0	0	0	0	0	0	0	0	0	0	2

Teniendo presente que  $Sens = TP / (TP + FN)$ , la  $Espec = TN / (TN + FP)$  y la  $Exac = TP + TN / (TP + FN + TN + FP)$ , respecto a la clase Flx0 la  $Sens_{Flx0} = 2 / (2 + 0) = 1$ , la  $Espec_{Flx0} = 22 / (22 + 0) = 1$  y la  $Exac_{Flx0} = 2 + 22 / (2 + 0 + 22 + 0) = 1$ . En la Tabla 11 se puede apreciar cómo se calculan de los diez sujetos de prueba con respecto a la clase Flx0 los promedios y las desviaciones estándar de las  $Sens_{Flx0}$ , las  $Espec_{Flx0}$  y las  $Exac_{Flx0}$  obtenidas.



Tabla 11. Ejemplo del cálculo con respecto a la clase Flx0 de los promedios y las desviaciones estándar de los valores que representan el desempeño del clasificador en la última prueba realizada

N° Sujeto de prueba	$Sens_{Flx0}$	$Espec_{Flx0}$	$Exac_{Flx0}$
1	1	1	1
2	0	0.95	0.88
3	1	0.95	0.96
4	1	0.90	0.92
5	0.5	1	0.96
6	0.5	1	0.96
7	1	1	1
8	1	1	1
9	1	0.95	0.96
10	1	1	1
Promedio ( <i>Prom</i> )	0.8	0.98	0.96
Desviación estándar ( $\sigma$ )	$\pm 0.35$	$\pm 0.04$	$\pm 0.04$

Se puede apreciar que los promedios y las desviaciones estándar corresponden con los valores declarados en la primera fila de la Tabla 9. De la misma forma fueron calculados todos estos valores para cada una de las 12 clases.



## 5) Discusión

Los resultados de la validez de la prueba del modelo fueron mostrados en la Tabla 9. De forma ideal tanto la sensibilidad como la especificidad deben ser 1 para asegurar que cualquier predicción sea válida o certera. Esto es poco probable ya que el hecho de que el modelo clasifique correctamente todas las señales que no se presentaron en su entrenamiento involucra que en las señales de prueba todas las condiciones y factores difíciles de conservar como el estado de fatiga muscular sean invariables. También se puede observar que la especificidad de todas las clases es alta, lo que significa que es baja la probabilidad de que se prediga un movimiento que no haya sido realizado.

Recapitulando, en la literatura del reconocimiento de patrones basado en electromiografía, la sensibilidad de cada clase es considerada como la exactitud de cada una de ellas, esta medida de desempeño también es conocida como “tasa correcta” [60]. Entonces todos los resultados que reportan exactitud en todos los trabajos de clasificación basados en electromiografía, representan en realidad las sensibilidades obtenidas en sus estudios [61], [62]. Aunque la sensibilidad promedio de todas las clases fue de 0.55, las sensibilidades en la Tabla 9 de las clases de flexión a 0°, extensión a 0°, supinación a 90° y supinación en abducción son altas, mayores o iguales a 0.75, se traduce en una probabilidad alta de predicción de estos cuatro movimientos en todos los sujetos de prueba. La posible razón de estos resultados puede deberse a que en la orientación del brazo a 0° el músculo del bíceps en los movimientos de flexión y extensión tiene que ejecutar un mayor momento de fuerza debido a que el antebrazo se llega a desplazar a una posición donde el momento de fuerza que produce la gravedad es máximo sobre este segmento corporal (la palanca de un músculo es máxima cuando el ángulo de inserción es de 90°). El movimiento de supinación seguramente es bien identificado debido a que cuando se ejecuta este con el brazo flexionado, dicho movimiento se asiste del músculo del bíceps, el cual fue monitoreado directamente por un canal de electromiografía.





Analizando la Tabla 1, una de las ventajas de este trabajo es que la cantidad de movimientos que involucra es mayor que en la mayoría de estos estudios. El trabajo realizado por León [2], es el único que manejó más movimientos que el presente estudio. Él reportó una exactitud muy alta de hasta 95% de clasificación identificando 27 clases. En su trabajo se utilizó una cantidad de ocho electrodos la cual es mayor que la usada en este trabajo, además de que sus clasificaciones fueron basadas en el análisis del estado estable de la señal y no así del estado transitorio como en el presente estudio.

La mayoría de trabajos del estado del arte como el de Huang et al [55], el de Chu [56] y el de Boschmann et al [3] tienen una relación baja respecto del número de movimientos al número de electrodos ( $N_m/N_{ch}$ ) lo que resulta en incrementar la identificación de patrones de los movimientos sacrificando la utilidad de sus sistemas al requerir más puntos de adquisición de las MES.

En este estudio la razón de adquirir los EMG del brazo en lugar del antebrazo derivó de destinar los esfuerzos de este trabajo a utilizarse posteriormente en personas que sólo tienen el muñón de su brazo debido a una amputación. La mayoría de trabajos como el de Nishikawa et al [53] toman sus registros directamente de los principales músculos responsables de la ejecución de los movimientos, lo que incrementa así también la exactitud de sus estudios.



## 6) Conclusiones

El clasificador desarrollado identificó movimientos articulares a partir del análisis de los primeros instantes de la contracción dinámica de los músculos a pesar de que el comportamiento de sus MES es estocástico. La dificultad de identificar los movimientos en el estado dinámico del movimiento, estriba en que las señales disminuyen su estacionariedad en esos instantes. La decisión de haber hecho predicciones a partir de estos momentos fue para reconocer durante el comienzo de la contracción muscular, el movimiento que pretende realizar el sujeto de prueba, permitiendo generar así de forma casi inmediata las señales de control del actuador o prótesis que se desee manipular.

Específicamente fueron desarrollados un programa para adquirir MES junto con datos de un sistema que estima orientación 3D y se realizó un método para clasificar movimientos a través de dicha información. Durante la ejecución de los movimientos fueron registradas al mismo tiempo tanto las señales electromiográficas de dos músculos del brazo, así como la orientación 3D estimada de la extremidad superior. Esto permitió obtener un clasificador que proporciona mayor exactitud en sus predicciones, usando no sólo información de los EMG sino también datos de un sistema que estima la orientación de la extremidad superior.

Las características en el dominio tiempo – frecuencia permitieron analizar comportamientos de las señales electromiográficas en distintos rangos de frecuencia a través del uso de herramientas matemáticas como la DWT. Los coeficientes Wavelet y la extracción de características temporales de la reconstrucción de las ventanas de análisis, a partir de la combinación de los coeficientes, permitieron disminuir la dimensionalidad de las características de cada instancia que usó el clasificador.

Aunque adquirir electromiográfica sólo en el brazo de los sujetos de prueba incrementó la dificultad del reconocimiento de los movimientos de supinación y pronación, ya que estos son producidos principalmente por los músculos del



antebrazo, estos se lograron identificar en el modelo desarrollado. La elección de sólo esta parte de la extremidad superior para la extracción de los EMG fue con el objetivo de poder utilizar el modelo clasificador desarrollado en personas con amputaciones por debajo del codo.

La prueba  $t$  de Student comprobó que existen diferencias estadísticamente significativas entre los valores de sensibilidad del modelo de la MPLNN que usa la orientación del brazo y los valores de sensibilidad del modelo de la MPLNN que no usa la orientación del brazo. Se rechazó la hipótesis nula con un nivel de confianza del 95% relativa a la similitud de sus clasificadores. Esto demostró que el uso de la orientación estimada del brazo a través de los módulos de monitoreo magneto inerciales aumenta significativamente la sensibilidad de las clasificaciones del modelo predictor, por lo que se propone usarse en conjunto con sistemas de reconocimiento de patrones electromiográficos para aumentar la exactitud de los modelos clasificadores.

Finalmente en un modelo virtual, se reproducen los movimientos articulares clasificados con ayuda de procesamiento de EMG no estacionarios y también con el uso de la información de la orientación 3D estimada del brazo, posibilitando identificar así en tres diferentes orientaciones del miembro superior la clase perteneciente de cada movimiento, analizando solo los primeros instantes de su ejecución.

Como trabajo futuro se propone usar el presente trabajo en sujetos de prueba amputados por debajo del codo para analizar y hacer las modificaciones pertinentes para que éste continúe siendo funcional. También sería de gran ayuda que de forma independiente a la orientación corporal y al tipo de movimiento que se ejecute se logre identificar automáticamente, el instante del comienzo del estado transitorio en las MES, pudiéndose así producir el funcionamiento en ese preciso instante del modelo clasificador desarrollado en este trabajo.



## Referencias

- [1] M. Hakonen, H. Piitulainen, y A. Visala, “Current state of digital signal processing in myoelectric interfaces and related applications”, *Biomed. Signal Process. Control*, vol. 18, pp. 334–359, 2015.
- [2] M. León Ponce, “Clasificación de patrones mioeléctricos para la operación de un dispositivo antropomórfico”, Ph.D. , Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, México, D.F., 2012.
- [3] A. Boschmann, B. Nofen, y M. Platzner, “Improving Transient State Myoelectric Signal Recognition in Hand Movement Classification using Gyroscopes”, en *35th Annual International Conference of the IEEE EMBS, Osaka, Japan*, 2013, pp. 6035–6038.
- [4] J. A. Barraza Madrigal, “Diseño y desarrollo de un sistema ambulatorio de análisis de movimiento: monitoreo, reproducción y seguimiento del hombro”, Ph.D. , Dpto. Ingeniería Eléctrica, Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, D.F. , México, 2016.
- [5] V. Voegeli, “Lecciones básicas de biomecánica del aparato locomotor”, Barcelona: Springer Science & Business Media, 2001, pp. 133–134.
- [6] N. Palastanga, D. Field, y R. Soames, “Anatomía y movimiento humano. Estructura y funcionamiento”, Barcelona: Editorial Paidotribo, 2007, p. 151.
- [7] A. P, “Términos de Movimiento”. [En línea]. Disponible en: <http://miradayvisionandrespuch.blogspot.mx/2009/09/terminos-de-movimiento.html>. [Consultado: 24-ene-2018].
- [8] L. J. H. Rosa Pérez, “Semiología de antebrazo, muñeca y mano”. [En línea]. Disponible en: [http://sisbib.unmsm.edu.pe/bibvirtual/libros/medicina/cirugia/tomo\\_ii/semiologia\\_amm.htm](http://sisbib.unmsm.edu.pe/bibvirtual/libros/medicina/cirugia/tomo_ii/semiologia_amm.htm). [Consultado: 24-jul-2017].
- [9] J. V Basmajian, *Muscles alive. Their functions revealed by electromyography*, vol. 37, núm. 8. Michigan: LWW, 1962.
- [10] “El codo y el antebrazo: biomecánica, articulaciones y técnicas de movilización”, 2014. [En línea]. Disponible en: <http://codoyantebrazo->



## Referencias

- cinesiterapiausj.blogspot.mx/2014/05/. [Consultado: 24-ene-2018].
- [11] F. B. Mattia, "Elsevier's dictionary of acronyms, initialisms, abbreviations and symbols", Milan: Elsevier, 2003, p. 249.
- [12] M. Torres Quezada, R. Sagaró Zamora, L. Broche Vázquez, D. Delisle Rodríguez, y A. López Delis, "Robotic Training System for Upper Limb Rehabilitation", *Ing. y Univ.*, vol. 18, núm. 2, pp. 235–252, 2014.
- [13] I. S. of E. Kinesiology, "Units, Terms and Standards in Reporting EMG Research", 1980, p. 1.
- [14] M. Á. Mañanas Villanueva, "Análisis de la actividad muscular respiratoria mediante técnicas temporales, frecuenciales y estadísticas", Cataluña: Universitat Politècnica de Catalunya, 1999, p. 18.
- [15] M. Knaflitz y G. Balestra, "Computer analysis of the myoelectric signal", *IEEE Micro*, vol. 11, núm. 5, pp. 12–15, 1991.
- [16] R. G. Radwin, S. Oh, T. R. Jensen, y J. G. Webster, "External finger forces in submaximal five-finger static pinch prehension", *Ergonomics*, vol. 35, núm. 3, pp. 275–288, 1992.
- [17] H. A. Romo, J. C. Realpe, P. E. Jojoa, y U. Cauca, "Surface EMG Signals Analysis and Its Applications in Hand Prosthesis Control", *Av. en Sist. e Informática*, vol. 4, núm. 1, pp. 127–136, 2007.
- [18] M. B. I. Reaz, M. S. Hussain, y F. Mohd-Yasin, "Techniques of EMG signal analysis: detection, processing, classification and applications", *Biol. Proced. Online*, vol. 8, núm. 1, pp. 11–35, 2006.
- [19] N. Nazmi, M. Abdul Rahman, S.-I. Yamamoto, S. Ahmad, H. Zamzuri, y S. Mazlan, "A Review of Classification Techniques of EMG Signals during Isotonic and Isometric Contractions", *Sensors*, vol. 16, núm. 8, pp. 1304–1331, 2016.
- [20] N. W. Willigenburg, A. Daffertshofer, I. Kingma, y J. H. van Dieën, "Removing ECG contamination from EMG recordings: A comparison of ICA-based and other filtering procedures", *J. Electromyogr. Kinesiol.*, vol. 22, núm. 3, pp. 485–493, 2012.
- [21] B. R. Kowalski y C. F. Bender, "Pattern recognition. Powerful approach to interpreting chemical data", *J. Am. Chem. Soc.*, vol. 94, núm. 16, pp. 5632–5639,



- 1972.
- [22] K. Englehart, B. Hudgins, y A. Chan, “Continuous multifunction myoelectric control using pattern recognition”, *Technol. Disabil.*, pp. 95–103, 2003.
  - [23] F. H. Y. Chan, Y.-S. Yang, F. K. Lam, Y.-T. Zhang, y P. A. Parker, “Fuzzy EMG classification for prosthesis control”, *IEEE Trans. Rehabil. Eng.*, vol. 8, núm. 3, pp. 305–311, 2000.
  - [24] N. Jiang, J. L. G. Vest-Nielsen, S. Muceli, y D. Farina, “EMG-based simultaneous and proportional estimation of wrist/hand kinematics in uni-lateral trans-radial amputees”, *J. Neuroeng. Rehabil.*, vol. 9, núm. 1, p. 42, jun. 2012.
  - [25] D. Graupe, J. Salahi, y K. Kohn, “Multifunctional prosthesis and orthosis control via microcomputer identification of temporal pattern differences in single-site myoelectric signals”, *J Biomed Eng*, vol. 4, pp. 17–22, 1982.
  - [26] T. W. Beck, T. J. Housh, G. O. Johnson, J. P. Weir, y J. T. Cramer, “Comparison of Fourier and wavelet transform procedures for examining the mechanomyographic and electromyographic frequency domain responses during fatiguing isokinetic muscle actions of the biceps brachii”, *Electromyogr. Kinesiol.*, vol. 15, núm. 2, pp. 190–199, 2005.
  - [27] M. A. M. Chowdhury, R.H.; Reaz, M.B.I.; Ali, “Surface Electromyography Signal Processing and Classification Techniques”, *Sensors*, vol. 13, pp. 12431–12466, 2013.
  - [28] H. Rechy-Ramirez, E.J.; Huosheng, “Bio-signal based control in assistive robots: A survey”, *Digit. Commun. Netw.*, vol. 1, pp. 85–101, 2015.
  - [29] S. A. Ahmad, “Moving Approximate Entropy and its Application to the Electromyographic Control of an Artificial Hand”, University of Southampton, Southampton, UK, 2009.
  - [30] K. Englehart, “Signal Representation for Classification of the Transient Myoelectric Signal”, University of New Brunswick, Saint John, NB, Canada, 1998.
  - [31] H. Oskoei, M.A.; Hu, “Myoelectric control systems—A survey”, *Biomed. Signal Process. Control*, vol. 2, pp. 275–294, 2007.
  - [32] A. Phinyomark, A. Nuidod, P. Phukpattaranont, y C. Limsakul, “Feature extraction and reduction of wavelet transform coefficients for EMG pattern



## Referencias

- classification”, *Elektron. ir Elektrotechnika*, vol. 122, núm. 6, pp. 27–32, 2012.
- [33] K. Englehart, B. Hudgin, y P. A. Parker, “A wavelet-based continuous classification scheme for multifunction myoelectric control”, *IEEE Trans. Biomed. Eng.*, vol. 48, núm. 3, pp. 302–311, 2001.
- [34] A. Phinyomark, C. Limsakul, y P. Phukpattaranont, “Application of Wavelet Analysis in EMG Feature Extraction for Pattern Classification”, *Meas. Sci. Rev.*, vol. 11, núm. 2, pp. 45–52, 2011.
- [35] X. Hu, Z. Wang, y X. Ren, “Classification of surface EMG signal using relative wavelet packet energy”, *Comput. Methods Programs Biomed.*, vol. 79, núm. 3, pp. 189–195, 2005.
- [36] R. Boostani y M. H. Moradi, “Evaluation of the forearm EMG signal features for the control of a prosthetic hand”, *Physiol. Meas.*, vol. 24, núm. 2, pp. 309–319, 2003.
- [37] M. P. Wachowiak, G. S. Rash, P. M. Quesada, y A. H. Desoky, “Wavelet-based noise removal for biomechanical signals: a comparative study”, *IEEE Trans. Biomed. Eng.*, vol. 47, núm. 3, pp. 360–368, 2000.
- [38] G. Cornelia y R. Romulus, “ECG signals processing using wavelets”, *Univ. Oradea Electron. Dep. Oradea, Rom.*, 2005.
- [39] “Wavelet Transform”. [En línea]. Disponible en: <http://gwyddion.net/documentation/user-guide-en/wavelet-transform.html>. [Consultado: 23-feb-2018].
- [40] İ. Güler y E. D. Übeyli, “Feature saliency using signal-to-noise ratios in automated diagnostic systems developed for ECG beats”, *Expert Syst. Appl.*, vol. 28, núm. 2, pp. 295–304, 2005.
- [41] E. D. Übeyli, “Wavelet/mixture of experts network structure for EEG signals classification”, *Expert Syst. Appl.*, vol. 34, núm. 3, pp. 1954–1962, 2008.
- [42] Y. J. Cho y J. Y. Kim, “The effects of load, flexion, twisting and window size on the stationarity of trunk muscle EMG signals”, *Int. J. Ind. Ergon.*, vol. 42, núm. 3, pp. 287–292, 2012.
- [43] Benedetti *et al.*, “Myoelectric Activation Pattern during Gait in Total Knee Replacement: Relationship with Kinematics, Kinetics, and Clinical Outcome”,



- IEEE Trans. Rehabil. Eng.*, vol. 7, núm. 2, pp. 140–149, 1999.
- [44] I. Hostens, J. Seghers, A. Spaepen, y H. Ramon, “Validation of the wavelet spectral estimation technique in biceps brachii and brachioradialis fatigue assessment during prolonged low-level static and dynamic contractions”, *J. Electromyogr. Kinesiol.*, vol. 14, núm. 2, pp. 205–215, 2004.
- [45] B. Karlsson, M. Berson, T. Helgason, R. T. Geirsson, y L. Pourcelot, “Effects of fetal and maternal breathing on the ultrasonic Doppler signal due to fetal heart movement”, *Eur. J. ultrasound*, vol. 11, núm. 1, pp. 47–52, 2000.
- [46] B. Karlik y A. V. Olgac, “Performance analysis of various activation functions in generalized MLP architectures of neural networks”, *Int. J. Artif. Intell. Expert Syst.*, vol. 1, núm. 4, pp. 111–122, 2011.
- [47] I. A. Basheer y M. Hajmeer, “Artificial neural networks: fundamentals, computing, design, and application”, *J. Microbiol. Methods*, vol. 43, núm. 1, pp. 3–31, 2000.
- [48] R. Chirala, “What is a simple explanation of how artificial neural networks work?”, 2015. [En línea]. Disponible en: <https://www.quora.com/What-is-a-simple-explanation-of-how-artificial-neural-networks-work-1/answer/Raviteja-Chirala>. [Consultado: 24-ene-2018].
- [49] J. Ladd Parada, “Caracterización y detección automática de los potenciales auditivos relacionados a eventos N100, P200 y Mismatch Negativity”, M.C. , Dpto. Ingeniería Eléctrica, Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, D.F. , México, 2012.
- [50] K. J. Cios, *Data mining : a knowledge discovery approach*. Nueva York: Springer, 2007.
- [51] C. R. Sabiote, J. G. Pérez, y T. P. Llorente, “Fundamentos conceptuales de las principales pruebas de significación estadística en el ámbito educativo”, en *LISLL, Ed.) Grupo Editorial Universitario*, 2007, pp. 8–10.
- [52] J. A. Barraza Madrigal, “Desarrollo de una prótesis virtual para extremidad superior con amputación por arriba de la articulación del codo”, M.C. , Dpto. Ingeniería Eléctrica, Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, D.F. , México, 2010.
- [53] D. Nishikawa, W. Y. Hiroshi Yoko, y Y. Kakazu, “On line Learning Method for





## Referencias

- EMG Prosthetic Hand Control”, *Electron. Commun. Japan*, vol. 84, núm. 10, 2001.
- [54] M. León Ponce, “Desarrollo de un sistema para la identificación de 7 movimientos de la mano basado en la señal mioeléctrica del antebrazo”, M.C. , Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, México, D.F., 2003.
- [55] Y. Huang, K. B. Englehart, B. Hudgins, y A. D. C. Chan, “A Gaussian Mixture Model Based Classification Scheme for Myoelectric Control of Powered Upper Limb Prostheses”, *IEEE Trans. Biomed. Eng.*, vol. 52, núm. 11, pp. 1801–1811, 2005.
- [56] J.-U. Chu, M. Inhyuk, y M. Mu-Seong, “A Real-Time EMG Pattern Recognition System Based on Linear-Nonlinear Feature Projection for a Multifunction Myoelectric Hand”, *IEEE Trans. Biomed. Eng.*, vol. 53, núm. 11, 2006.
- [57] M. Pla Mobarak, “Trasient state analysis of the multichannel EMG signal for identification of hand movements”, M.C. , Dpto. Ingeniería Eléctrica, Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, D.F. , México, 2014.
- [58] J. A. Barraza Madrigal, R. Muñoz Guerrero, L. L. Salas, y R. Ranta, “Instantaneous Position and Orientation of the Body Segments as an Arbitrary Object in 3D space by merging gyroscope and accelerometer information”, *Rev. Mex. Ing. Biomédica*, vol. 35, núm. 3, pp. 241–252, 2014.
- [59] D. Blana, T. Kyriacou, J. M. Lambrecht, y E. K. Chadwick, “Feasibility of using combined EMG and kinematic signals for prosthesis control: A simulation study using a virtual reality environment”, *J. Electromyogr. Kinesiol.*, vol. 29, pp. 21–27, 2016.
- [60] T. Jiralerspong, E. Nakanishi, C. Liu, y J. Ishikawa, “Experimental Study of Real-Time Classification of 17 Voluntary Movements for Multi-Degree Myoelectric Prosthetic Hand”, *Appl. Sci.*, vol. 7, núm. 11, p. 1163, 2017.
- [61] G. Gaudet, M. Raison, y S. Achiche, “Classification of Upper limb phantom movements in transhumeral amputees using electromyographic and kinematic features”, *Eng. Appl. Artif. Intell.*, vol. 68, núm. October 2017, pp. 153–164, 2018.



## Referencias

- [62] X. Chen y Z. J. Wang, “Biomedical Signal Processing and Control Pattern recognition of number gestures based on a wireless surface EMG system”, *Biomed. Signal Process. Control*, vol. 8, núm. 2, pp. 184–192, 2013.
- [63] SENIAM, “Recommendations for sensor locations in arm or hand muscles”. [En línea]. Disponible en: [http://seniam.org/arm\\_location.htm](http://seniam.org/arm_location.htm). [Consultado: 27-sep-2017].
- [64] “SENIAM Sensor Locations: Triceps brachii”. [En línea]. Disponible en: <http://seniam.org/tricepsbrachiilateralhead.html>. [Consultado: 24-ene-2018].
- [65] “SENIAM Sensor Locations: Biceps brachii”. [En línea]. Disponible en: <http://seniam.org/bicepsbrachii.html>. [Consultado: 24-ene-2018].
- [66] C. I. De Luca, “The Use of Surface Electromyography in Biomechanics”, *J. Appl. Biomech.*, vol. 13, pp. 135–163, 1997.
- [67] R. Merletti y D. Farina, “Surface electromyography: physiology, engineering, and applications”, Nueva Jersey: John Wiley & Sons, 2016, p. 97.
- [68] R. Merletti y P. A. Parker, “Electromyography: physiology, engineering, and non-invasive applications”, vol. 11, Nueva Jersey: John Wiley & Sons, 2004, p. 121.
- [69] Olimex, “SHIELD-EKG-EMG bio-feedback shield USER’S MANUAL”, 2014.
- [70] “SHIELD-EKG-EMG - Open Source Hardware Board”. [En línea]. Disponible en: <https://www.olimex.com/Products/Duino/Shields/SHIELD-EKG-EMG/>. [Consultado: 24-ene-2018].
- [71] Olimex, “SHIELD-EKG-EMG-PA data sheet”. 2014.
- [72] “SHIELD-EKG-EMG-PA - Open Source Hardware Board”. [En línea]. Disponible en: <https://www.olimex.com/Products/Duino/Shields/SHIELD-EKG-EMG-PA/open-source-hardware>. [Consultado: 24-ene-2018].
- [73] “Arduino Uno Rev3”. [En línea]. Disponible en: <https://store.arduino.cc/usa/arduino-uno-rev3>. [Consultado: 24-ene-2018].
- [74] Panasonic, “Standard Lithium-ion Battery Pack UR-123”, 2011.
- [75] D. Blana, T. Kyriacou, J. M. Lambrecht, y E. K. Chadwick, “Feasibility of using combined EMG and kinematic signals for prosthesis control: A simulation study using a virtual reality environment”, *J. Electromyogr. Kinesiol.*, vol. 29, pp. 21–27, 2016.



## Referencias

- [76] “Computer Animation Representing A 3d-man Sitting In Front Of A Green Desktop”. [En línea]. Disponible en: <https://www.shutterstock.com/video/clip-818761-stock-footage-computer-animation-representing-a-d-man-sitting-in-front-of-a-green-desktop.html>. [Consultado: 24-ene-2018].
- [77] “Músculos del hombro”. [En línea]. Disponible en: <http://elsistemamuscular.blogspot.mx/2012/02/musculos-del-hombro.html>. [Consultado: 03-ago-2017].
- [78] G. Fierro, “Anatomía del hombro”. [En línea]. Disponible en: <http://guidofierro.com/diagnostico-y-tratamiento/hombro/anatomia-del-hombro/>. [Consultado: 24-ene-2018].
- [79] H. Gray, *Anatomy of the human body*, vol. 20. Filadelfia y Nueva York: Lea & Febiger, 1918.
- [80] T. Matsubara y J. Morimoto, “Bilinear modeling of EMG signals to extract user-independent features for multiuser myoelectric interface”, *IEEE Trans. Biomed.*, vol. 60, núm. 8, pp. 2205–2213, 2013.
- [81] A. Phinyomark, F. Quaine, S. Charbonnier, C. Serviere, F. Tarpin-Bernard, y Y. Laurillau, “EMG feature evaluation for improving myoelectric pattern recognition robustness”, *Expert Syst. Appl.*, vol. 40, núm. 12, pp. 4832–4840, 2013.
- [82] T. R. Farrell y R. F. Weir, “The Optimal Controller Delay for Myoelectric Prostheses”, *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 15, núm. 1, pp. 111–118, mar. 2007.
- [83] “Overfitting in Machine Learning: What It Is and How to Prevent It”, 2017. [En línea]. Disponible en: <https://elitedatascience.com/overfitting-in-machine-learning>. [Consultado: 24-ene-2018].
- [84] M. Hudson Beale, M. T. Hagan, y H. B. Demuth, “Neural Network Toolbox™ 7 User’s Guide”, en *MathWorks*, Massachusetts, 2010, p. “3-16”.
- [85] H. Al-Angari, G. Kanitz, y S. Tarantino, “Distance and mutual information methods for EMG feature and channel subset selection for classification of hand movements”, *Biomed. Signal Process. Control*, vol. 27, pp. 24–31, 2016.
- [86] “Evaluación del rendimiento de un modelo en Machine Learning | Microsoft Docs”. [En línea]. Disponible en: <https://docs.microsoft.com/es->



## Referencias

- mx/azure/machine-learning/studio/evaluate-model-performance. [Consultado: 01-oct-2017].
- [87] A. Phinyomark, C. Limsakul, y P. Phukpattaranont, "Evaluation of Mother Wavelets based on Robust EMG Feature Extraction using Wavelet Packet Transform", *13th Anu. Symp. Comput. Sci. Eng.*, núm. APRIL, pp. 333–339, 2009.
- [88] M. F. Lucas, A. Gaufriau, S. Pascual, C. Doncarli, y D. Farina, "Multi-channel surface EMG classification using support vector machines and signal-based wavelet optimization", *Biomed. Signal Process. Control*, vol. 3, núm. 2, pp. 169–174, 2008.
- [89] M. Hollander, D. A. Wolfe, y E. Chicken, *Nonparametric statistical methods*, 3a ed., vol. 751. Nueva York: John Wiley & Sons, 2013.
- [90] C. Beleites, R. Salzer, y V. Sergo, "Validation of soft classification models using partial class memberships: an extended concept of sensitivity & co. applied to grading of astrocytoma tissues", *Chemom. Intell. Lab. Syst.*, vol. 122, pp. 12–22, 2013.



## Anexo A. Modificación física de la tarjeta *SHIELD EMG-EKG* Olimex

