



Universidad Autónoma de Querétaro
 Facultad de Ingeniería
 Maestría en Ciencias en Inteligencia Artificial

DETECCIÓN Y CLASIFICACIÓN DE SEÑALES MIOELÉCTRICAS EN EL
 BRAZO MEDIANTE EL USO DE ALGORITMOS BASADOS EN INTELIGENCIA
 ARTIFICIAL

Opción de titulación
Tesis

Que como parte de los requisitos para obtener el Grado de
 Maestro en Ciencias en Inteligencia Artificial

Presenta:
 Iván Joel Ramírez Ángeles

Dirigido por:
 Dr. Marco Antonio Aceves Fernández

Dr. Marco Antonio Aceves Fernández
 Presidente

Firma

Dr. Jesús Carlos Pedraza Ortega
 Secretario

Firma

Dr. Saúl Tovar Arriaga
 Vocal

Firma

Dr. Juvenal Rodríguez Reséndiz
 Suplente

Firma

Dr. Luis Alberto Torres Salomao
 Suplente

Firma

Dr. Manuel Toledano Ayala
 Director de la Facultad de Ingeniería

Dra. Ma. Guadalupe Flavia Loarca Piña
 Director de Investigación y Posgrado

Centro Universitario
 Querétaro, Qro.
 Abril 2019

RESUMEN

Por un gran periodo de tiempo el funcionamiento del cuerpo humano ha sido base de múltiples investigaciones, permitiendo avances en el estudio de señales tales como las señales electroencefalográficas (EEG) producidas por la actividad cerebral, señales electromiográficas (EMG) generadas por el movimiento de los músculos estriados, también conocidos como esqueléticos, y las señales electrocardiográficas (ECG) que registran la actividad cardíaca. El entendimiento y uso de estas señales han permitido desarrollar múltiples aplicaciones para tanto para uso clínico o como para la industria.

Las señales EMG se han convertido en una herramienta importante en la rehabilitación debido a la facilidad con la que pueden ser extraídas por métodos no invasivos para la persona tal como la electromiografía de superficie (sEMG). Las señales recolectadas por sEMG proveen información acerca de la actividad neuromuscular que la origina y han sido fundamentales para el uso en diagnósticos clínicos y desarrollo de aplicaciones para rehabilitación o recreación.

Esta investigación se propone explorar el análisis de las señales electromiográficas para su clasificación con algoritmos de Inteligencia Artificial. Se presenta la metodología para la recolección de las señales EMG y tratamiento de estas con la implementación de algoritmos de inteligencia artificial, con la finalidad de clasificar las señales por movimiento.

(Palabras clave: electromiografía (emg), algoritmos de inteligencia artificial, procesamiento de señales, reducción de parámetros)

SUMMARY

The understanding of the human body has been topic of research for a long time resulting in the studies of bioelectric signals or bio signals such as electroencephalographic (EEG) signals originated by brain activity, electromyographic (EMG) signals originated by muscular activity or electrocardiographic (ECG) signals originated by cardiac activity. The study of these signals has allowed the develop of multiple applications for either clinical or industry use.

EMG signals have become an important tool for rehabilitation due the ease to collect them using noninvasive methods for example surface electromyography (sEMG).

In this investigation it is proposed to use machine learning (ML) algorithms to classify correctly the EMG signals with the right movement, allowing multiple applications in rehabilitation, home automation or recreation.

(Keywords: electromyography (emg), artificial intelligence algorithms, signal processing, parameter reduction).

A mi familia: madre, padre y hermana, por acompañarme hasta el final.

Una dedicatoria especial al Dr. Marco Aceves por inspirarme al camino de la investigación y seguir picando piedra.

AGRADECIMIENTOS

Quiero manifestar mi más sincero agradecimiento a:

La Universidad Autónoma de Querétaro y al CONACYT por permitirme la oportunidad de terminar mis estudios de Maestría.

Mi director de tesis Marco Antonio Aceves Fernández, mis maestros Jesús Carlos Pedraza, Juan Manuel Ramos Arreguín, Saúl Tovar Arriaga, Arturo Gutiérrez González, Emilio Vargas Soto y Efrén Gorrostieta Hurtado, por su guía, paciencia y no negarme nunca un consejo.

Naela Razo, Mayra Cortes, Fer Rojo, Lorena Rodríguez y Kenny Ruiz, por el trabajo interdisciplinario y la paciencia de enseñarme y compartirme sus conocimientos.

Santiago Fraga por apoyarme con la información necesaria para no reinventar la rueda.

A mis compañeros de generación, Edgar Altamirano y Rogelio Román, por su apoyo cuando las cosas no iban bien para uno o para los tres.

“Si he visto más lejos es porque estoy sentado sobre los hombros de gigantes”

Isaac Newton

TABLA DE CONTENIDOS

1. INTRODUCCIÓN	16
1.1 INTELIGENCIA ARTIFICIAL.....	16
1.1.1 La Prueba de Turing.....	16
1.1.2 Aprendizaje Supervisado y No Supervisado	18
1.2 SEÑALES ELECTROMIOGRÁFICAS (EMG).....	19
1.3 JUSTIFICACIÓN	25
1.4 DESCRIPCIÓN DEL PROBLEMA	25
1.5 HIPÓTESIS	26
1.6 OBJETIVO GENERAL	27
1.7 OBJETIVOS ESPECÍFICOS	27
2. MARCO TEÓRICO	28
2.1 PROCESO ELÉCTRICO DEL MÚSCULO ESQUELÉTICO	28
2.2 TOPOLOGÍA MUSCULAR.....	29
3. MATERIALES Y MÉTODOS	31
3.1 PROTOCOLO DE PRUEBAS.....	31
3.1.1 Riesgos	32
3.1.2 Molestias	32
3.1.3 Beneficios.....	32
3.1.4 Incentivos	32
3.1.5 Buenas Prácticas de Laboratorio.....	32
3.1.6 Grupo de Estudio.....	32

3.1.7	Formatos de Confidencialidad	33
3.2	SOFTWARE Y HARDWARE	33
3.3	METODOLOGÍA DE EXPERIMENTOS PARA LA ADQUISICIÓN DE SEÑALES EMG .	35
3.3.1	Recolección de las Señales	36
3.3.2	Proceso de Invitación y Consentimiento de Estudio.....	37
3.3.3	Obtención de Datos.....	39
3.4	EXTRACCIÓN DE CARACTERÍSTICAS	48
3.4.1	Transformada de Fourier (FT)	48
3.4.2	Transformada Wavelet (WT)	49
3.4.3	Wavelet Denoising.....	50
3.4.4	Caracterización de las señales.....	52
3.4.5	Integrated EMG (IEMG).....	52
3.4.6	Mean Absolute Value (MAV)	53
3.4.7	Modified Mean Absolute Value type 1 and type 2 (MAV1, MAV2).....	53
3.4.8	Simple Square Integral (SSI).....	54
3.4.9	Variance of EMG (VAR)	54
3.4.10	Absolute Value of the 3rd, 4th, and 5th Temporal Moment (TM3, TM4, TM5).....	54
3.4.11	Root Mean Square (RMS)	55
3.4.12	v-Order (VO)	55
3.4.13	Log Detector (LOG)	55
3.4.14	Waveform Length (WL).....	56
3.4.15	Average Amplitude Change (AAC)	56

3.4.16	Difference Absolute Standard Deviation Value (DASDV)	56
3.4.17	Zero Crossing (ZC)	56
3.4.18	Myopulse Percentage Rate (MYOP)	57
3.4.19	Willison Amplitude (WAMP)	57
3.4.20	Reducción de Dimensionalidad.....	58
3.4.21	Rough Sets (RS).....	58
3.4.22	Análisis de Componentes Principales (PCA)	60
3.5	CLASIFICACIÓN.....	61
3.5.1	K-Media (K-Means Clustering)	62
3.5.2	Vecino más cercano (kNN).....	63
3.6	EVALUACIÓN DE DESEMPEÑO	64
3.6.1	Exactitud, Sensibilidad y Especificidad (Accuracy, Sensitivity and Specificity).....	65
4.	RESULTADOS Y DISCUSIÓN	68
4.1	EXPERIMENTACIÓN	68
4.2	DISCUSIÓN DE RESULTADOS	83
5.	CONCLUSIONES	129
	REFERENCIAS.....	130
	APÉNDICE.....	136

ÍNDICE DE FIGURAS Y TABLAS

Fig. 1.1. Definiciones de la IA, organizadas en cuatro categorías de acuerdo con Russell, S. J. 2016	16
Fig. 1.2 Niveles de la IA (Creación Propia)	18
Fig. 1.3. Categorías del Aprendizaje Supervisado y sus aplicaciones. (Creación Propia)	19
Fig. 1.4. Origen de una señal EMG (Creación Propia)	20
Fig. 1.5. Electrodo Intramusculares (Recuperado de http://www.dalcame.com/emg.html)	20
Fig. 1.6. Electrodo de Superficie (Creación Propia)	21
Fig. 1.7. Diagrama a bloques del módulo de electromiografía (Adaptado de Asghari Oskoei, M., & Hu, H., 2007)	22
Fig. 1.8. (a) Conceptualización de una electromiografía. (b) Señal EMG resultante. (Creaciones Propias)	23
Fig. 1.9. Gráfica de un Filtro Notch (Adaptación de Proakis, John G., and Dimitris G. Manolakis. 2014)	24
Fig. 1.10. Fases de desarrollo del proyecto	26
Fig. 2.1. Representación del mecanismo de control básico y la unidad motora (MU) y sus componentes (Creación Propia)	28
Fig. 2.2. Electromiografía de Superficie, Costa, David & Duarte, Carlos. (2015)	29
Fig. 2.3. Mapa Muscular por Anatomía muscular. ¿Qué es?, fisiología y mucho más. (2018). [online] Disponible en: http://tucuerpohumano.com/c-sistema-muscular/anatomia-muscular/ [Último acceso 24 ago. 2018]	30
Fig. 3.1. Brazaletes Myo, lee la actividad eléctrica en los músculos mediante técnicas no invasivas (Myo, 2016).	34
Fig. 3.2. Capturas del software EMGSR	34
Fig. 3.3. Diagrama de bloques de la metodología propuesta.	35
Fig. 3.4. Gráfico que representa la cantidad de participantes divididos en grupos de edad y género.	36
Fig. 3.5. Diagrama de flujo que describe el proceso de invitación y consentimiento al estudio	38
Fig. 3.6. Ubicación del indicador LED del brazaletes (Myo, 2016)	39

Fig. 3.7. Software necesario para el procedimiento (https://www.myo.com/start)	40
Fig. 3.8. Myo Connect con una conexión exitosa	40
Fig. 3.9. Ubicación de postura del brazalete Myo (Myo, 2016)	40
Fig. 3.10. Ventana de captura de las señales de un movimiento	42
Fig. 3.11 Lista de movimientos, (a) Posición Inicial o Reposo, (b) Pronación, (c) Supinación, (d) Extensión, (e) Flexión, (f) Desviación Cubital, (g) Desviación Radial, (h) Pinza Fina, (i) Pinza Gruesa, (j) Expansión o Abducción de Dedos	44
Fig. 3.12. Nombramiento de los canales.	45
Fig. 3.13. Diagrama de flujo que describe el proceso de obtención de datos.	47
Fig. 3.14. Graficas de una señal antes y después de su filtrado y su espectro usando FFT (Creación Propia)	49
Fig. 3.15. Señal original y con eliminación de ruido utilizando wavelet denoising (Creación Propia)	52
Fig. 3.16. Reducción de Dimensionalidad, en la figura a se puede apreciar un conjunto de atributos completos, en la figura b, se eliminan aquellos que sean inciertos, indiscernibles de otros o puedan causar ruido en nuestro entrenamiento, en la figura c se muestran las características elegidas para el entrenamiento. (Creación Propia)	58
Fig. 3.17. Diagrama de bloques de PCA	60
Fig. 3.18. (a) Grafico original de los atributos de los datos. (b) Grafico de los datos normalizados con los eigenvectores de la matriz de covarianza superpuesta. (c) La grafica de los datos aplicando PCA. (d) Reconstrucción de los datos usando un eigenvector (Gráficos por Smith, L. I., 2002).	61
Fig. 3.19. Sistema de información graficada sin grupos definidos (Creación Propia).	62
Fig. 3.20. Agrupamiento de datos con su centroide calculado, donde se obtienen tres grupos resultantes (Creación Propia).	63
Fig. 3.21. Predicción del valor desconocido utilizando 3 vecinos más cercanos (Creación Propia).	64
Fig. 3.22. La predicción del valor desconocido cambia si utilizamos 5 vecinos en lugar de 3 (Creación Propia).	65
Fig. 3.23 Casos de ejemplo para valores de una hipótesis (Creación Propia)	66

Fig. 4.1 Señales filtradas de los ocho canales para el movimiento flexión para ambos brazos	69
Fig. 4.2. La matriz S almacena los valores de la señal mientras la matriz I almacena las características para su posterior entrenamiento y decisión.	70
Fig. 4.3. Proceso de segmentación de la señal.	71
Fig. 4.4. La matriz S ahora almacena cada señal segmentada, mientras que la matriz I almacena también a que repetición corresponde.	72
Fig. 4.5. La matriz F almacena las características extraídas de cada señal mientras que la matriz IF almacena la información acerca de la señal correspondiente.	72
Fig. 4.6. Separación del sistema de información de las señales, el grupo de entrenamiento y el grupo de prueba.	74
Fig. 4.7. El sistema de información original fue separado en dos grupos, el grupo de entrenamiento y el grupo de pruebas.	76
Fig. 4.8. Diagrama de flujo para la obtención de pesos de los centroides de las características.	77
Fig. 4.9. De la matriz de señales de entrenamiento (SE) se extraen sus características (FE) y se calculan sus centroides por cada brazo (FMD y FMI).	78
Fig. 4.10. Calculo de distancias entre movimiento original y entrada	79
Fig. 4.11. Diagrama de flujo para la clasificación de una señal	80
Fig. 4.12. Matriz de distancias de movimientos	81
Fig. 4.13. Diagrama de flujo detallando el proceso de clasificación	82
Fig. 4.15. Comparación de señales en bruto y filtradas para el movimiento posición inicial en el brazo derecho.	84
Fig. 4.16. Comparación de señales en bruto y filtradas para el movimiento posición inicial en el brazo izquierdo.	85
Fig. 4.17. Comparación de señales en bruto y filtradas para el movimiento pronación en el brazo derecho.	86
Fig. 4.18. Comparación de señales en bruto y filtradas para el movimiento pronación en el brazo izquierdo.	87
Fig. 4.19. Comparación de señales en bruto y filtradas para el movimiento supinación en el brazo derecho.	88
Fig. 4.20. Comparación de señales en bruto y filtradas para el movimiento supinación en el brazo izquierdo.	89

Fig. 4.21. Comparación de señales en bruto y filtradas para el movimiento extensión en el brazo derecho	90
Fig. 4.22. Comparación de señales en bruto y filtradas para el movimiento extensión en el brazo izquierdo.	91
Fig. 4.23. Comparación de señales en bruto y filtradas para el movimiento flexión en el brazo derecho.	92
Fig. 4.24. Comparación de señales en bruto y filtradas para el movimiento flexión en el brazo izquierdo.	93
Fig. 4.25. Comparación de señales en bruto y filtradas para el movimiento desviación cubital en el brazo derecho	94
Fig. 4.26. Comparación de señales en bruto y filtradas para el movimiento desviación cubital en el brazo izquierdo.	95
Fig. 4.27. Comparación de señales en bruto y filtradas para el movimiento desviación radial en el brazo derecho.	96
Fig. 4.28. Comparación de señales en bruto y filtradas para el movimiento desviación radial en el brazo izquierdo.	97
Fig. 4.29. Comparación de señales en bruto y filtradas para el movimiento pinza fina en el brazo derecho	98
Fig. 4.30. Comparación de señales en bruto y filtradas para el movimiento pinza fina en el brazo izquierdo.	99
Fig. 4.31. Comparación de señales en bruto y filtradas para el movimiento pinza gruesa en el brazo derecho.	100
Fig. 4.32. Comparación de señales en bruto y filtradas para el movimiento pinza gruesa en el brazo izquierdo.	101
Fig. 4.33. Comparación de señales en bruto y filtradas para el movimiento expansión en el brazo derecho.	102
Fig. 4.34. Comparación de señales en bruto y filtradas para el movimiento expansión en el brazo izquierdo.	103
Fig. 4.35 (a). Gráfica Radial de Centroides de la característica AAC para el brazo derecho	104
Fig. 4. 35 (b). Gráfica Radial de Centroides de la característica AAC para el brazo izquierdo	104
Fig. 4.36 (a). Gráfica Radial de Centroides de la característica DASDV para el brazo derecho	105

Fig. 4.36 (b). Gráfica Radial de Centroides de la característica DASDV para el brazo izquierdo	105
Fig. 4.37 (a). Gráfica Radial de Centroides de la característica IEMG para el brazo derecho	106
Fig. 4.37 (b). Gráfica Radial de Centroides de la característica IEMG para el brazo izquierdo	106
Fig. 4.38 (a). Gráfica Radial de Centroides de la característica LD para el brazo derecho	107
Fig. 4.38 (b). Gráfica Radial de Centroides de la característica LD para el brazo izquierdo	107
Fig. 4.39 (a). Gráfica Radial de Centroides de la característica MAV para el brazo derecho	108
Fig. 4.39 (b). Gráfica Radial de Centroides de la característica MAV para el brazo izquierdo	108
Fig. 4.40 (a). Gráfica Radial de Centroides de la característica MAV1 para el brazo derecho	109
Fig. 4.40 (b). Gráfica Radial de Centroides de la característica MAV1 para el brazo izquierdo	109
Fig. 4.41 (a). Gráfica Radial de Centroides de la característica MAV2 para el brazo derecho	110
Fig. 4.41 (b). Gráfica Radial de Centroides de la característica MAV2 para el brazo izquierdo	110
Fig. 4.42 (a). Gráfica Radial de Centroides de la característica MTW para el brazo derecho	111
Fig. 4.42 (b). Gráfica Radial de Centroides de la característica MTW para el brazo izquierdo	111
Fig. 4.43 (a). Gráfica Radial de Centroides de la característica MYOP para el brazo derecho	112
Fig. 4.43 (b). Gráfica Radial de Centroides de la característica MYOP para el brazo izquierdo	112
Fig. 4.44 (a). Gráfica Radial de Centroides de la característica PF para el brazo derecho	113
Fig. 4.44 (b). Gráfica Radial de Centroides de la característica PF para el brazo izquierdo	113

Fig. 4.45 (a). Gráfica Radial de Centroides de la característica RMS para el brazo derecho	114
Fig. 4.45 (b). Gráfica Radial de Centroides de la característica RMS para el brazo izquierdo	114
Fig. 4.46 (a). Gráfica Radial de Centroides de la característica SQI para el brazo derecho	115
Fig. 4.46(b). Gráfica Radial de Centroides de la característica SQI para el brazo izquierdo	115
Fig. 4.47 (a). Gráfica Radial de Centroides de la característica SSC para el brazo derecho	116
Fig. 4.47 (b). Gráfica Radial de Centroides de la característica SSC para el brazo izquierdo	116
Fig. 4.48 (a). Gráfica Radial de Centroides de la característica TM3 para el brazo derecho	117
Fig. 4.48 (b). Gráfica Radial de Centroides de la característica TM3 para el brazo izquierdo	117
Fig. 4.49 (a). Gráfica Radial de Centroides de la característica TM4 para el brazo derecho	118
Fig. 4.49 (b). Gráfica Radial de Centroides de la característica TM4 para el brazo izquierdo	118
Fig. 4.50 (a). Gráfica Radial de Centroides de la característica TM5 para el brazo derecho	119
Fig. 4.50 (b). Gráfica Radial de Centroides de la característica TM5 para el brazo izquierdo	119
Fig. 4.51 (a). Gráfica Radial de Centroides de la característica VAR para el brazo derecho	120
Fig. 4.51 (b). Gráfica Radial de Centroides de la característica VAR para el brazo izquierdo	120
Fig. 4.52 (a). Gráfica Radial de Centroides de la característica VO para el brazo derecho	121
Fig. 4.52 (b). Gráfica Radial de Centroides de la característica VO para el brazo izquierdo	121
Fig. 4.53 (a). Gráfica Radial de Centroides de la característica WAMP para el brazo derecho	122

Fig. 4.53 (b). Gráfica Radial de Centroides de la característica WAMP para el brazo izquierdo	122
Fig. 4.54 (a). Gráfica Radial de Centroides de la característica WL para el brazo derecho	123
Fig. 4.54 (b). Gráfica Radial de Centroides de la característica WL para el brazo izquierdo	123
Fig. 4.55 (a). Gráfica Radial de Centroides de la característica ZC para el brazo derecho	124
Fig. 4.55 (b). Gráfica Radial de Centroides de la característica ZC para el brazo izquierdo	124
Fig. 4.56. Gráfica Boxplot con los resultados de la eficacia de clasificación por atributo, se observa que RMS, DASDV y VO son los mejores atributos para realizar una clasificación.	126
Tabla 3.1. Especificaciones técnicas MYO (Traducido del inglés de Myo, 2016).	34
Tabla 3.2. Relación de Canal-Músculo	45
Tabla 3.3. Relación de Movimientos-Canal	46
Tabla 3.4. Lista de las 324 funciones wavelet agrupadas en 15 tipos ó familias (Traducida de Chowdhury, R.et al., 2013)	51
Tabla 3.5. Ejemplo de un sistema de información, donde hay siete casos u objetos y dos atributos: edad y puntuación de la extremidad inferior del motor (LEMS) (Traducido de Komorowski, J. et al., 1999).	59
Tabla 3.6. El atributo de decisión permite tomar decisiones basándonos en la información del sistema de información (Traducido de Komorowski, J. et al., 1999).	59
Tabla 4.1. Tabla de resultados de extracción de características	75
Tabla 4.2. Tabla de centroides resultantes por cada brazo para una sola característica.	78
Tabla 4.3. Agrupación de movimientos por amplitud de señal	125
Tabla 4.4. Agrupación de movimientos por amplitud de señal	128

1. INTRODUCCIÓN

1.1 Inteligencia Artificial

La inteligencia se puede definir como la habilidad que permite aprender, entender, razonar y tomar decisiones basadas en un conocimiento previo; gracias a esta habilidad se pueden elegir las mejores opciones para resolver un problema. La IA busca simular esta habilidad utilizando el procesamiento de computo de hoy en día y paradigmas de programación como: Redes Neuronales Artificiales (Artificial Neural Network), Aprendizaje Automático (Machine Learning, ML), Computación Evolutiva (Evolutionary Computation), Inteligencia de Enjambre (Swarm Intelligence), Sistema Inmune Artificial (Artificial Immune Systems), Sistemas Difusos (Fuzzy Systems), entre otros (Engelbrecht, Andries P., 2007). Stuart J. Russell (2016) realizó un compilado de definiciones de IA y las organizó en cuatro categorías como se muestra a continuación en la figura 1.1.



Fig. 1.1. Definiciones de la IA, organizadas en cuatro categorías de acuerdo con Russell, S. J. 2016

1.1.1 La Prueba de Turing

La primera persona en darle un enfoque a la IA fue Alan Turing quien, a mediados de 1900, creía que, si una computadora estaba programada de forma adecuada, podría ejecutar las mismas funciones que un ser humano. La Prueba de

Turing, propuesto el mismo (Turing, A.M., 1950), fue diseñada con la finalidad de exhibir un comportamiento inteligente similar al de un ser humano indistinguible de este.

Actualmente programar a una computadora para completar la prueba de Turing exitosamente debe poseer las siguientes capacidades (Russell, S. J., & Norvig, P., 2016):

- Procesamiento del Lenguaje Natural, para comunicarse exitosamente con su evaluador.
- Representación del Conocimiento, para almacenar la información prevista antes o durante el examen.
- Razonamiento Automatizado, para usar la información almacenada para dar una respuesta o asumir conclusiones.
- Aprendizaje Automático (ML), para adaptarse a nuevas circunstancias y detectar y extrapolar patrones.

Un mapa visual de los diferentes niveles que componen a una IA puede observarse en la siguiente figura.

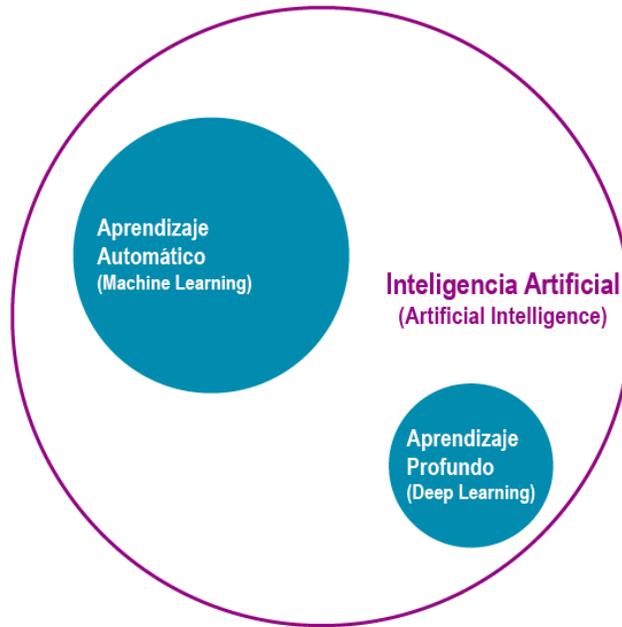


Fig. 1.2 Niveles de la IA (Creación Propia)

La IA se encuentra fundamentada en varias ciencias y estudios: Filosofía (425 a. C. - actualidad), Matemáticas (800 – actualidad), Psicología (1879 – actualidad), Ingeniería Computacional (1940 – actualidad) y Lingüísticas (1957 – actualidad).

1.1.2 Aprendizaje Supervisado y No Supervisado

Actualmente las áreas de aplicación y oportunidad de la IA son tan extensas que se necesitaría un compendio para explicar cada una, por mencionar algunas: procesamiento de lenguaje natural (Natural Language Processing), robótica, visión artificial, minería de datos (Big Data & Data Mining) (Nils J. Nilsson, 1980). Por esta razón se decidió clasificar los algoritmos de ML en aprendizaje supervisado y no supervisado, como se puede observar en la siguiente imagen.

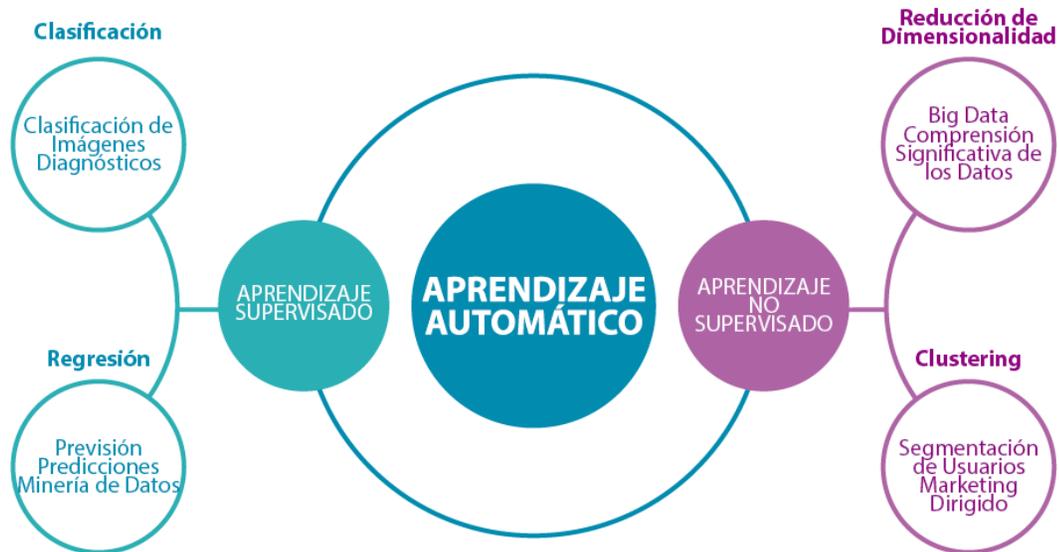


Fig. 1.3. Categorías del Aprendizaje Automático y sus aplicaciones. (Creación Propia)

1.2 Señales Electromiográficas (EMG)

El movimiento a voluntad de los organismos vertebrados se debe gracias al sistema muscular por el cual están compuestos; este sistema está constituido por una variedad de músculos inervados, conocidos como músculos esqueléticos o estriados (Costanzo, L. S., 2011). Las Señales EMG (figura 1.4) son las señales eléctricas producidas por músculos estriados durante el proceso de contracción y relajación. Estas señales son originadas por el intercambio de iones a través de las membranas de las fibras musculares debido a una contracción muscular.

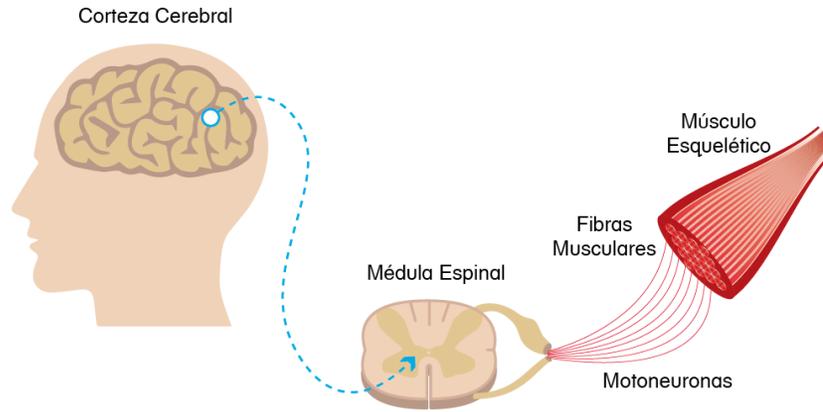


Fig. 1.4. Origen de una señal EMG (Creación Propia).

La electromiografía permite recolectar estas señales, actualmente existe la electromiografía invasiva y de superficie, ambas técnicas permiten adquirir, registrar y analizar la actividad eléctrica generada en los músculos estriados inervados, a través del uso de electrodos, la diferencia consiste en que la electromiografía clásica usa electrodos intramusculares, o de aguja, (figura 1.5) mientras que la electromiografía de superficie (sEMG) usa electrodos superficiales (figura 1.6).



Fig. 1.5. Electrodo Intramusculares (Recuperado de <http://www.dalcame.com/emg.html>).

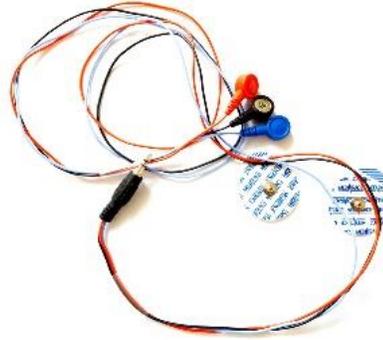


Fig. 1.6. Electrodo de Superficie (Creación Propia).

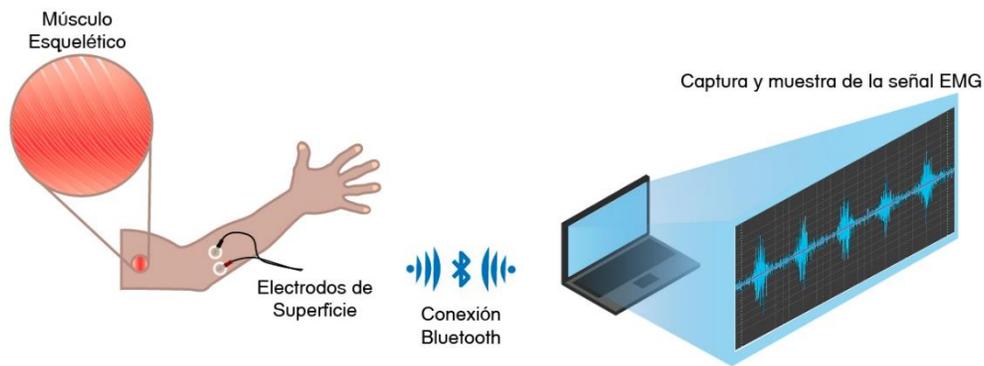
Estas mediciones proporcionan datos valiosos acerca de los patrones de la actividad muscular. La amplitud y las propiedades de las señales EMG tanto en el dominio del tiempo como en la frecuencia dependen de factores tales como: el tiempo y la intensidad de la contracción muscular, la distancia entre el electrodo y la zona de actividad muscular, las propiedades de la piel (por ejemplo, el espesor de la piel y tejido adiposo), las propiedades del electrodo y el amplificador y la calidad del contacto entre la piel y el electrodo.

En el proceso de una electromiografía se adhieren o colocan los electrodos a la piel del paciente sobre el músculo, la unidad de procesamiento contiene circuitos eléctricos que amplifican, filtran y digitalizan la señal adquirida (el diagrama de bloques de la figura 1.7 muestra este proceso), mientras que una computadora se utiliza para graficar las señales en dominio del tiempo.

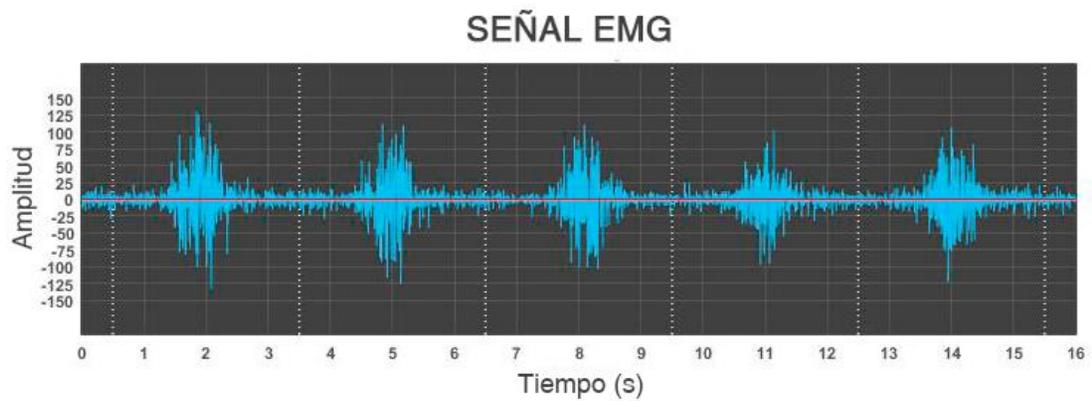
La representación y de una EMG puede ser observada en la siguiente figura, así como la señal obtenida por uno de los electrodos (figura 1.8).



Fig. 1.7. Diagrama a bloques del módulo de electromiografía (Adaptado de Asghari Oskoei, M., & Hu, H., 2007).



(a)



(b)

*Fig. 1.8. (a) Conceptualización de una electromiografía. (b) Señal EMG resultante.
(Creaciones Propias)*

La amplitud y anchura de banda de la señal EMG no están determinada únicamente por las fuentes electrofisiológicas y sus distancias hasta los electrodos, sino también por los tipos y tamaños de electrodos utilizados y por el espaciamiento entre electrodos. En este caso los electrodos de superficie van unidos a la piel sobre el segmento muscular que se está estudiando. El espaciamiento entre electrodos

determina el volumen de registro o recepción del tejido, resultando los espaciamientos más pequeños en registros más selectivos.

Debido a que las señales mioeléctricas son de baja intensidad, ruidos o artefactos como el ruido ambiente o en mayor medida el ruido de línea (50Hz – 60Hz) pueden provocar una falsa interpretación de los resultados, por eso es necesario un filtro rechaza banda.

El filtro elimina banda (“Notch Filter”) se caracteriza por rechazar una frecuencia determinada que este interfiriendo a un circuito, en nuestro caso la frecuencia de 60Hz que es generada por la línea de potencia. El circuito se ve expuesto a ruido ambiental que proviene de las lámparas fluorescentes y otros dispositivos que emiten ruido a través de ondas de 60 Hz. El filtro notch, (Figura 1.9), se encargará de rechazar exclusivamente el ruido de 60 Hz para entregar a la salida una señal con las mínimas distorsiones.

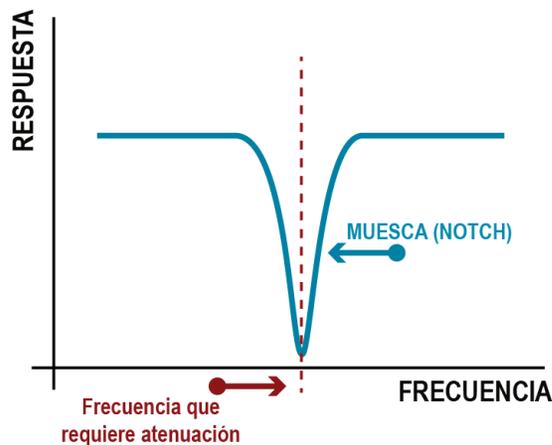


Fig. 1.9. Grafica de un Filtro Notch (Adaptación de Proakis, John G., and Dimitris G. Manolakis. 2014).

1.3 Justificación

Las señales EMG han tomado importancia con el tiempo debido a sus múltiples aplicaciones, incluyendo aplicaciones clínicas o biomédicas, prótesis, rehabilitación, o interfaces humano máquina (HMI, por sus siglas en inglés) (Chowdhury, R. et al., 2013). A pesar de ello, el trabajar con las señales EMG es un trabajo arduo debido a la complejidad en la detección, procesamiento y extracción de características, por esa razón se presenta a la IA como herramienta para la solución de estos problemas, debido a su éxito en la solución de distintos problemas en múltiples áreas de conocimiento. Por esta razón se proponen los algoritmos de ML para ayudar a resolver el problema de ruido, dimensionalidad y clasificación de las señales EMG.

En los últimos años ha habido múltiples estudios e investigaciones sobre la clasificación precisa y eficiente de las señales EMG, es aquí donde se busca implementar algoritmos de IA buscando mejorar estos parámetros de extracción de características, reducción y clasificación.

1.4 Descripción del problema

La fisioterapia, se define por la Confederación Mundial para la Terapia Física, como: “La terapia física y sus servicios proporcionados por terapeutas físicos a individuos y población para desarrollar, mantener y restaurar el movimiento máximo y la capacidad funcional a lo largo de la vida. El servicio es proporcionado en circunstancias donde el movimiento y la funcionalidad son amenazados por la edad, lesiones, dolor, enfermedades, desordenes, condiciones o factores ambientales y con la comprensión de que el movimiento funcional es fundamental para lo que significa ser saludable (Adaptado de World Confederation for Physical Therapy, 2011).

La fisioterapia debe de ser un trabajo especializado para cada paciente en rehabilitación; pero muchas veces a causa de la obsolescencia equipo o las limitantes del tiempo para consulta entre paciente y fisioterapeuta, no se puede llevar un avance constante, y en gran mayoría de los casos el tratamiento suele ser a prueba y error, causando un avance lento en la recuperación del paciente.

Este trabajo busca crear una interfaz que identifique el movimiento del antebrazo de una persona utilizando el brazalete MYO y un algoritmo de IA para clasificar las señales correctamente; permitiendo el uso de aplicaciones para rehabilitación muscular dentro y fuera de la clínica. El proceso del trabajo puede observarse en la figura 1.10.

La aportación de este trabajo se enfocará en los dos primeros bloques, la adquisición de señales EMG y la clasificación con algoritmos de ML.



Fig. 1.10. Fases de desarrollo del proyecto.

El éxito de muchas interfaces o sistemas de control se debe al correcto reconocimiento de patrones de señales EMG, por lo que se espera que la IA nos proporcione un enfoque acertado para resolver este problema.

1.5 Hipótesis

La extracción efectiva de características es necesaria para una clasificación fiable y, en la búsqueda de mejorar la precisión de la clasificación de patrones de señales mioeléctricas transitorias, se propone un conjunto de representaciones basadas en la frecuencia-tiempo (Englehart K. et al., 1999). Es viable realizar la

clasificación de señales EMG de un banco de datos utilizando algoritmos de limpieza, extracción de características, reducción y clasificación.

1.6 Objetivo General

Realizar la recolección de señales EMG, implementar un algoritmo de ML para la extracción de características, reducción y clasificación.

1.7 Objetivos Específicos

- Generar un banco de datos de señales EMG.
- Extraer las características de las señales.
- Implementar un algoritmo para la reducción de dimensionalidad (seleccionar las características más significativas).
- Implementar un algoritmo de clasificación para relacionar las señales de entrada con uno de los movimientos del banco de señales.

2. MARCO TEÓRICO

2.1 Proceso eléctrico del músculo esquelético

El sistema nervioso central se encuentra organizado de forma jerárquica. Las salidas de la corteza motora primaria tienen una poderosa influencia en las interneuronas y motoneuronas del tronco cerebral y de la médula espinal. Existe un vínculo entre el tracto corticoespinal y las alfa-motoneuronas, que proporcionan un control cortical directo de la actividad muscular, como se observa en la figura 2.1.

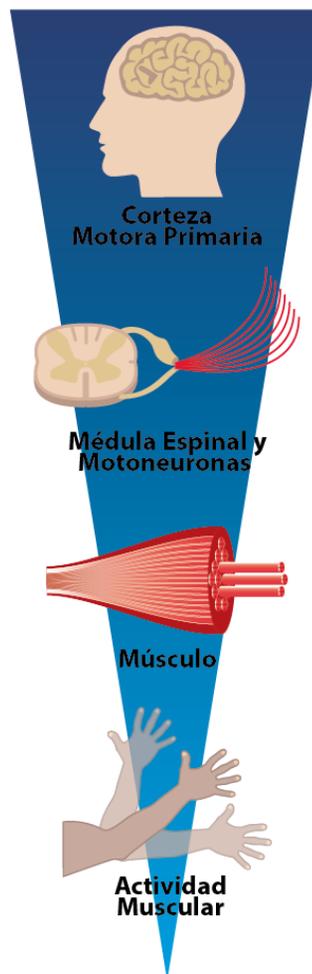


Fig. 2.1. Representación del mecanismo de control básico y la unidad motora (MU) y sus componentes (Creación Propia).

Existen varias técnicas para recolectar esta información eléctrica:

- Electroencefalograma (EEG)
- Electroencefalografía (ECoG)
- Electromiografía (EMG)

Las dos primeras técnicas registran la actividad cerebral, (de donde nace la señal que lleva la información del movimiento del músculo) mientras que la EMG registra la señal de los músculos inervados.

La EMG cuenta con técnicas invasivas y no invasivas, en este estudio se utilizó la electromiografía de superficie (sEMG), debido a que los electrodos se colocan directamente sobre la piel los resultados de la sEMG suelen mostrar una señal con más ruido debido a las interferencias eléctricas que pueden existir.



Fig. 2.2. Electromiografía de Superficie, Costa, David & Duarte, Carlos. (2015)

2.2 Topología Muscular

Los músculos registrados en el experimento fueron los siguientes:

- Tríceps
- Supinador

- Extensor Carpo
- Braquiorradial
- Braquial
- Pronador
- Flexor Superficial
- Flexor Profundo

La ubicación de estos músculos se puede observar en la figura siguiente:

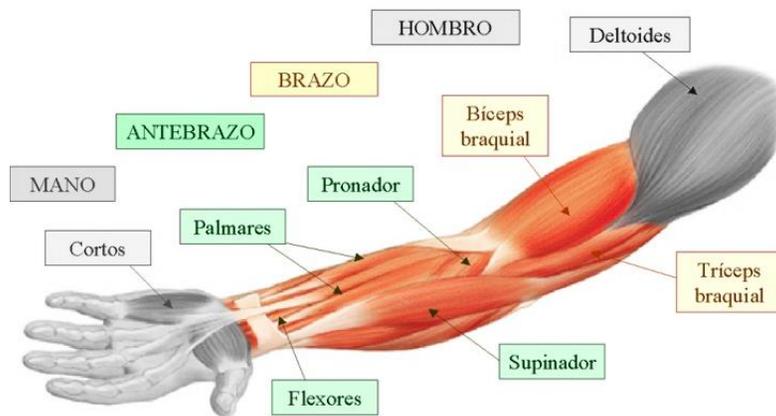


Fig. 2.3. Mapa Muscular por Anatomía muscular. *¿Qué es?, fisiología y mucho más.* (2018).
 [online] Disponible en: <http://tucuerpohumano.com/c-sistema-muscular/anatomia-muscular/> [Último acceso 24 ago. 2018].

3. MATERIALES Y MÉTODOS

3.1 Protocolo de Pruebas

Este estudio se basa en las consideraciones éticas planteadas en el tratado de Pautas Éticas Internacionales para la Investigación Biomédica en Seres Humanos (Favaloro, A. D. R., 2008) por el Consejo de Organizaciones Internacionales de las Ciencias Médicas (CIOMS) en colaboración con la Organización Mundial de la Salud (OMS) en donde se describen los principios éticos generales para un estudio en seres humanos.

Toda investigación en seres humanos debe realizarse de acuerdo con tres principios éticos básicos: respeto por las personas, beneficencia y justicia (Pautas Éticas Internacionales para la Investigación Biomédica en Seres Humanos, 2002).

El respeto por la autonomía de todas las personas implica que las personas capaces de deliberar sobre sus decisiones sean tratadas con respeto por su capacidad de autodeterminación y la protección de las personas con autonomía disminuida o deteriorada, que implica que se debe proporcionar seguridad contra daño o abuso de todas las personas dependientes o vulnerables.

La beneficencia refiere a la obligación ética de maximizar el beneficio y minimizar el daño a los participantes de estudio.

La justicia se refiere a la obligación ética de tratar de manera moralmente correcta y apropiada, con énfasis a las personas dependientes o vulnerables, que participen en el estudio.

Sobre la información personal del voluntario, esta quedará resguardada y protegida bajo las leyes mexicanas de protección de información. Por esta razón, al momento de presentar los resultados del estudio solamente se presentarán los datos relacionados con el mismo.

3.1.1 Riesgos

El presente estudio no genera ningún riesgo para el participante de estudio. Debido a que el estudio que se realizará es no invasivo, por lo que el participante de estudio no presentará ninguna molestia después debido al estudio. Sin embargo, no se eximen riesgos mínimos al participante por presentar reacciones adversas conocidos o previsibles durante el proceso de estudio.

3.1.2 Molestias

El brazalete está diseñado para que una persona lo use diariamente sin presentar molestias excesivas.

3.1.3 Beneficios

La presente investigación permitirá obtener un banco de datos de señales EMG con características y elementos específicos que permitirá entrenar la interfaz que clasifique los movimientos y las señales correctamente.

3.1.4 Incentivos

No hay ningún incentivo económico al participar en este proyecto, así como no se ofrecerán regalos, servicios o algún otro recurso material o económico.

3.1.5 Buenas Prácticas de Laboratorio

El estudio al ser no invasivo y con un brazalete de uso comercial, no presenta ninguna complicación para ser utilizado. Por lo mismo no existe un riesgo de desecho de electrodos superficiales, de aguja, o material toxico.

3.1.6 Grupo de Estudio

Los sujetos que participen en la elaboración de las pruebas descritas en este protocolo deben presentarse de manera voluntaria y estar de acuerdo con el procedimiento, firmar la carta de consentimiento y la carta de confidencialidad. En

caso de ser menores de edad el consentimiento para participar en las pruebas deberá ser autorizado y firmado por alguno de sus padres o tutores.

Sujetos pertenecientes a grupos sociales no vulnerables, sujetos sanos, ambos sexos, de edad indistinta, indistinto si son diestros o zurdos. Se excluyen a las mujeres embarazadas.

3.1.7 Formatos de Confidencialidad

El presente estudio presenta dos cartas de confidencialidad que buscan proteger la información del participante de estudio, así como al investigador. Estas se encuentran en los anexos.

3.2 Software y Hardware

Para el desarrollo del presente trabajo se utilizó un brazalete “Myo Armband”, desarrollado por ThalmicLabs™ (figura 3.1); su funcionamiento consiste en leer la actividad eléctrica de los músculos y el movimiento del brazo, gracias a sus sensores EMG de acero inoxidable de grado médico, su giroscopio, acelerómetro y magnetómetro, esta lectura permitirá recopilar datos suficientes para usarlos en un algoritmo de aprendizaje automático. La tabla 3.1 muestra sus especificaciones técnicas.

Para la adquisición de datos se utilizó el software EMGSR (Figura 3.2), desarrollado por la Universidad Autónoma de Querétaro. El equipo de cómputo utilizado para el desarrollo del presente trabajo se utilizó una computadora portátil marca Lenovo modelo Y700 con un procesador Intel Core i7-6700 a 2.6 GHz con 8 GB de memoria RAM bajo el sistema operativo Windows 10 de 64 bits.



Fig. 3.1. Brazaletes Myo, lee la actividad eléctrica en los músculos mediante técnicas no invasivas (Myo, 2016).

Tabla 3.1. Especificaciones técnicas MYO (Traducido del inglés de Myo, 2016).

Sensores	Sensores EMG de acero inoxidable de grado médico, IMU de nueve ejes altamente sensible que contiene un giroscopio de tres ejes, acelerómetro de tres ejes, magnetómetro de tres ejes
LED	Indicador LED dual
Procesador	Procesador ARM Cortex M4
Retroalimentación Háptica	Vibraciones cortas, medianas y largas



Fig. 3.2. Capturas del software EMGSR.

3.3 Metodología de Experimentos para la Adquisición de Señales EMG

La metodología propuesta se muestra en el siguiente diagrama de bloques. Cada bloque cuenta con una serie de procesos internos que también se describen a detalle.

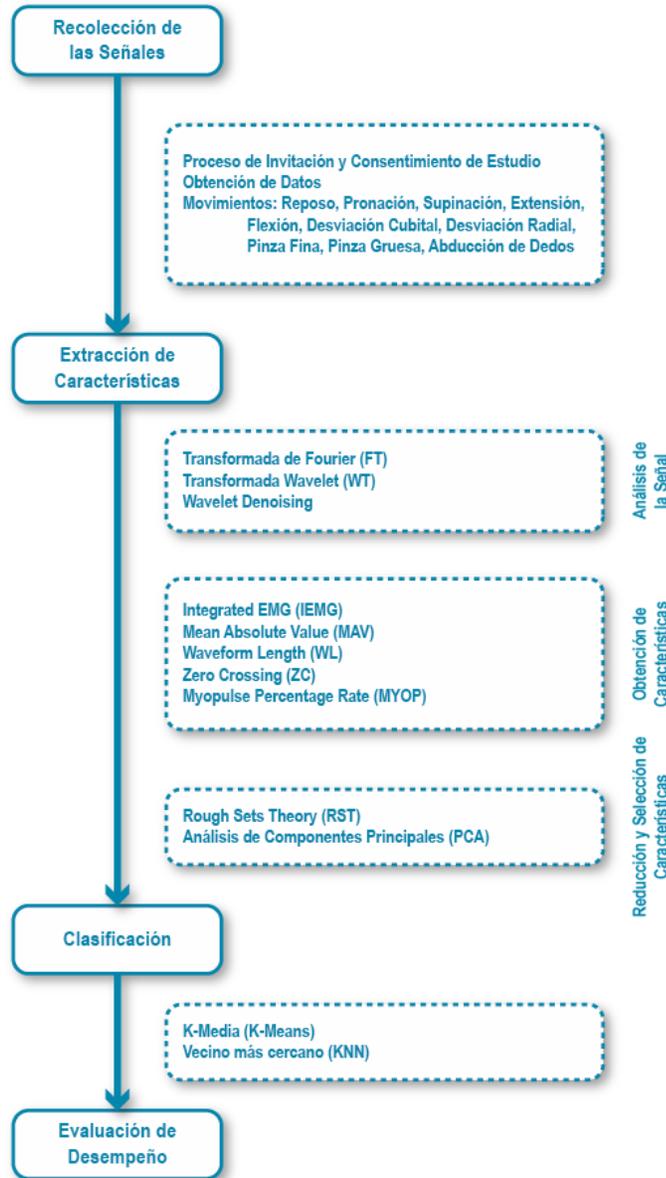


Fig. 3.3. Diagrama de bloques de la metodología propuesta.

3.3.1 Recolección de las Señales

Se recolectaron las señales a partir de 50 participantes en una buena condición de salud (sin enfermedades neuromusculares o embarazadas ni lactancia). Los participantes se encuentran en un rango de 18 y 60 años, con la finalidad de obtener la mayor variación de señales. La media de la edad de los participantes se encuentra en 31 años, y se cuentan con un registro de 21 participantes masculinos y 27 femeninos (Figura 3.4).

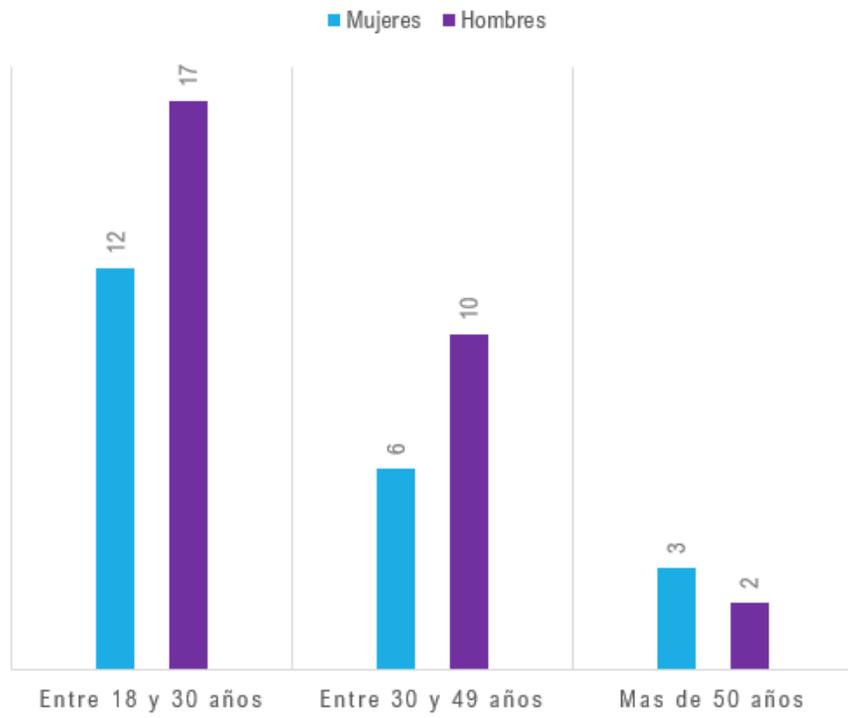


Fig. 3.4. Gráfico que representa la cantidad de participantes divididos en grupos de edad y género.

A continuación, se describe el proceso llevado a cabo para la recolección de señales EMG.

3.3.2 Proceso de Invitación y Consentimiento de Estudio

Se invitará al posible participante, previamente seleccionado del grupo de estudio, a formar parte de la prueba y se le explicará brevemente y de manera clara en que consiste el estudio, lo que se busca realizar con los datos que proporcione y la confidencialidad de estos. Si el voluntario presenta dudas en esta sección, se le brindará la información necesaria para resolverlas. En dado caso que el voluntario no desee continuar, se le agradecerá por su tiempo y se finalizará el proceso de invitación, por otra parte si el invitado desea continuar se le explicará en que consiste la prueba, el equipo que se va a utilizar para realizarla y se aclarará que es un estudio no invasivo por lo que no sufrirá ninguna molestia durante ni después del estudio, si el voluntario presenta dudas, estas deberán ser respondidas en su totalidad y si no desea seguir con el estudio se agradecerá su tiempo y finalizará el proceso, pero si desea continuar se procederá a firmar la carta de consentimiento de estudio y la carta de confidencialidad (Apéndice). Este proceso se describe en la figura 3.5.

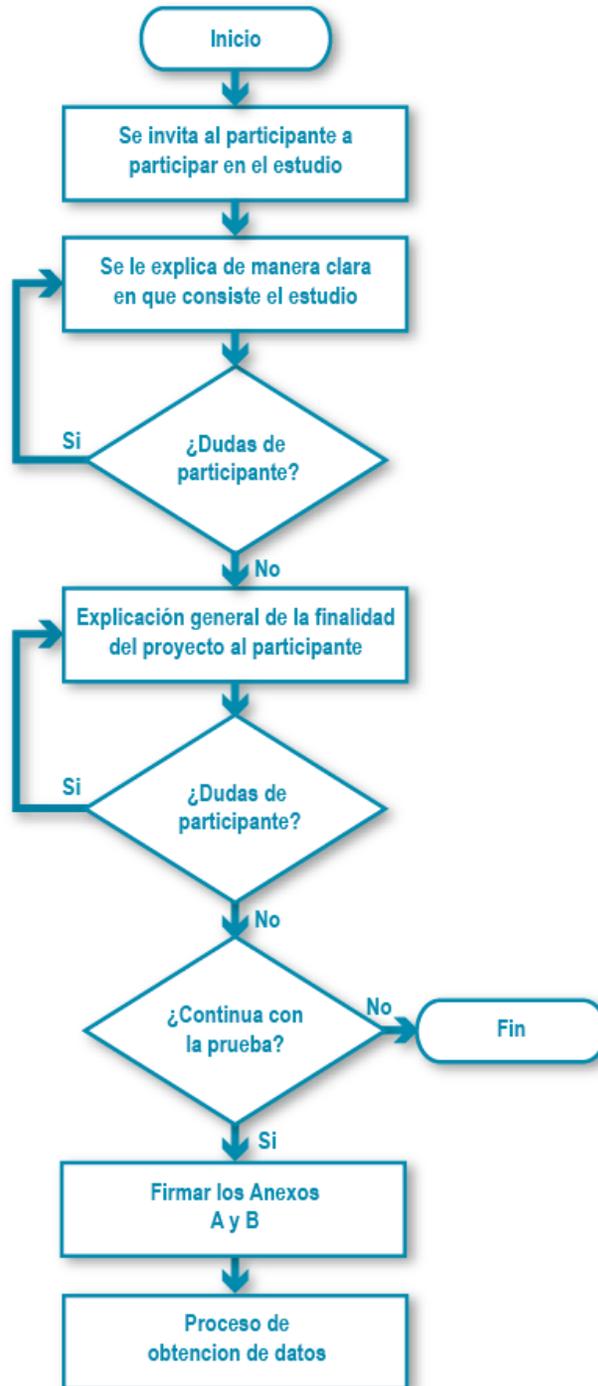


Fig. 3.5. Diagrama de flujo que describe el proceso de invitación y consentimiento al estudio

3.3.3 Obtención de Datos

Para dar inicio al proceso de obtención de pruebas, se necesita contar con el brazalete Myo, el brazalete cuenta con un sensor led que permite revisar el estado de este como se muestra en la figura 3.6; si el led se encuentra azul el brazalete se encuentra listo y conectado, si se encuentra naranja será necesario cargar el brazalete. Para las pruebas se recomienda que el led del Myo se encuentre en azul.



Fig. 3.6. Ubicación del indicador LED del brazalete (Myo, 2016)

Antes de iniciar el protocolo es necesario instalar ambos programas, tanto el programa nativo para la conexión del brazalete con la computadora, como el software de recolección de señales (Figura 3.7).

Para iniciar el brazalete es necesario conectarlo a una computadora por medio del cable USB, una vez conectado se debe desconectar y el indicador LED debe de prender en color azul, si el LED prende en otro color, será necesario revisar las especificaciones del MYO para determinar la causa.

El adaptador bluetooth se debe conectar a la computadora para establecer una conexión con el brazalete. Para comprobar la conexión del brazalete con la computadora es necesario abrir el programa "Myo Connect" y revisar los parámetros de conexión (Figura 3.8).

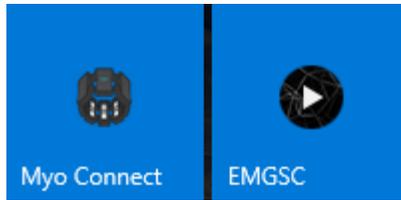


Fig. 3.7. Software necesario para el procedimiento (<https://www.myo.com/start>).

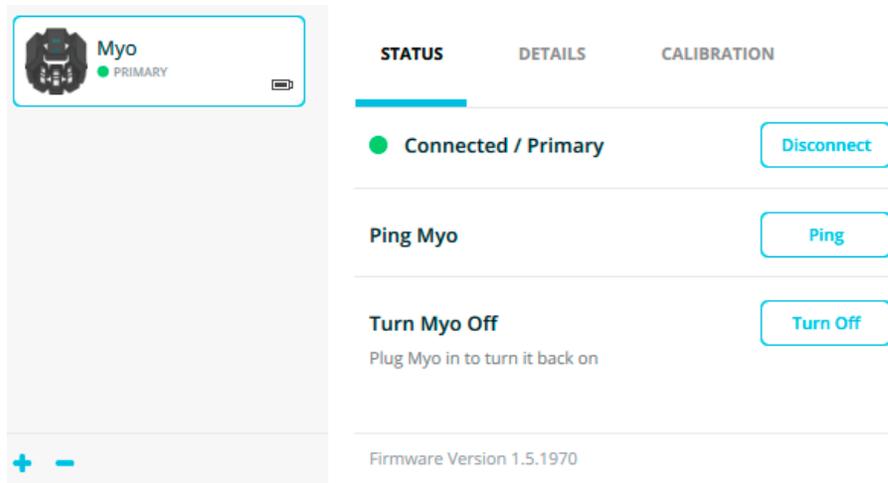


Fig. 3.8. Myo Connect con una conexión exitosa.

El brazalete se colocará en la parte superior del antebrazo del voluntario como se muestra en la figura 3.9, siempre procurando que el logotipo y el led queden visibles. Se debe tener cuidado de que cada electrodo haga contacto directamente con la piel, si el brazalete no se ajusta a la persona, se deberán usar los clips que vienen incluido con el Myo.



Fig. 3.9. Ubicación de postura del brazalete Myo (Myo, 2016).

Una vez que el brazalete se encuentre en su postura, se procederá a realizar pruebas de comunicación para comprobar la calidad de la señal, si esta no es exitosa se procede a ajustar nuevamente el brazalete y realizar nuevamente la prueba de la señal hasta que sea exitosa. A continuación, se procederá a registrar los datos del usuario en la interfaz del programa EMGSC, posteriormente el programa solicitará saber de qué brazo se están recolectando las señales, y a continuación se mostrarán diferentes ventanas con los movimientos para recolectar las señales de cada uno, primeramente antes de realizar el movimiento, el programa mostrará un vídeo de corta duración indicando como realizar correctamente el movimiento, la siguiente ventana del programa pausará el video y mostrara una barra de progreso de dieciséis segundos de duración así como las señales EMG (Figura 3.10), durante la cual el participante deberá repetir el movimiento 5 veces en cada intervalo de tres segundos, iniciando desde el momento en que la pulsera lo indique con una breve vibración. El voluntario procederá a realizar los movimientos todos descritos en la prueba y las señales que genere se irán registrando mediante el software y el brazalete. Si todas las pruebas han sido ejecutadas correctamente para un brazo, el mismo procedimiento se repetirá para el siguiente brazo. Finalmente, completado la recolección se retirará el brazalete del voluntario se le agradecerá por su tiempo y se dará por terminado el proceso de obtención de datos de ese participante. En todos los movimientos es necesario que el participante se encuentre de pie, observando la pantalla de frente sin girar el cuello y manteniendo levantado el antebrazo de estudio en un ángulo de 90 grados, como se observa en la figura 3.11 (a). La figura 3.10 muestra una captura del software funcionando y recolectando las señales mientras muestra al voluntario como realizar el movimiento.



Fig. 3.10. Ventana de captura de las señales de un movimiento.

La lista de movimientos que se diseñaron para la recolección de señales, fueron la siguiente, listándose en orden de ejecución.

- Posición Inicial (Reposo), en esta postura el participante se mantendrá la palma extendida con los dedos cerrados, sin ejercer demasiada fuerza en los mismos. De esta postura iniciaran los movimientos subsecuentes (Fig. 3.11a).
- Pronación. Brazo pegado al tronco, codo en flexión de 90° , mano en posición inicial, se procede a hacer el movimiento; se gira la palma de la mano con vista hacia abajo y se regresa a la posición inicial (Fig. 3.11b).
- Supinación. Brazo pegado al tronco, codo en flexión de 90° , mano en posición inicial, se procede a hacer el movimiento; se gira la palma de la mano con vista hacia arriba y se regresa a la posición inicial (Fig. 3.11c).
- Extensión. Brazo pegado al tronco, codo en flexión de 90° , mano en posición inicial, se procede a hacer el movimiento; sin mover el codo se lleva la palma de la mano hacia afuera y se regresa a la posición inicial (Fig. 3.11d).

- Flexión. Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; sin mover el codo se lleva la palma de la mano hacia adentro, con vista hacia el cuerpo y se regresa a la posición inicial (Fig. 3.11e).
- Desviación Cubital. Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; sin mover el codo se inclina la mano hacia abajo y se regresa a la posición inicial (Fig. 3.11f).
- Desviación Radial. Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; sin mover el codo se inclina la mano hacia arriba ligeramente y se regresa a la posición inicial (Fig. 3.11g).
- Pinza Fina. Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; se tocan las yemas de los dedos del pulgar y el índice, se regresan a la posición inicial (Fig. 3.11h).
- Pinza Gruesa (Cerrar Puño). Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; se hace un puño dejando el pulgar afuera sobre los demás dedos y se regresa a la posición inicial (Fig. 3.11i).
- Expansión (Abducción de Dedos). Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; se separan todos los dedos y se regresan hacia la posición inicial (Fig. 3.11j).

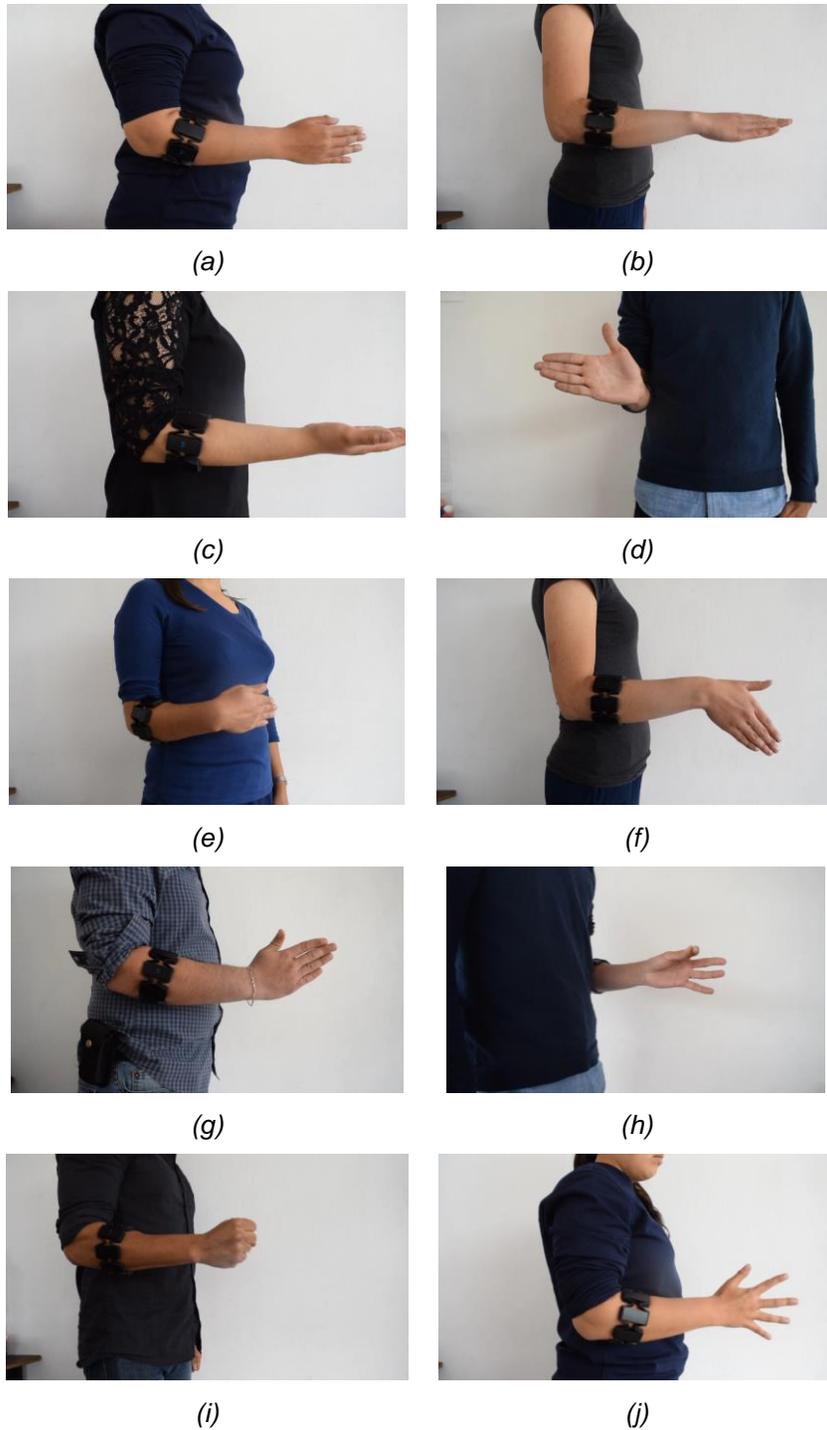


Fig. 3.11 Lista de movimientos, (a) Posición Inicial o Reposo, (b) Pronación, (c) Supinación, (d) Extensión, (e) Flexión, (f) Desviación Cubital, (g) Desviación Radial, (h) Pinza Fina, (i) Pinza Gruesa, (j) Expansión o Abducción de Dedos.

Con la finalidad de poder crear una relación entre los canales (electrodos), los músculos y movimientos, cada canal se etiquetaron del uno al siete, el orden de los canales se muestra en la figura a continuación.

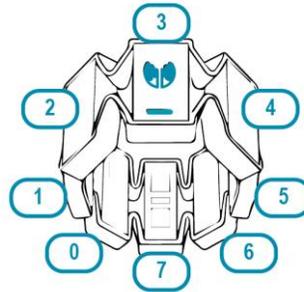


Fig. 3.12. Nombramiento de los canales.

La relación de canales-músculo y canales-movimiento, se muestran en las tablas 3.2 y 3.3.

Tabla 3.2. Relación de Canal-Músculo

Canales	Músculos
Canal 1	Tríceps
Canal 2	Extensores, Supinador
Canal 3	Epicóndilo, Extensores, Extensor Carpo
Canal 4	Extensores, Braquiorradial
Canal 5	Braquial, Flexores
Canal 6	Flexores, Pronador
Canal 7	Epitróclea, Flexores, Flexor Superficial
Canal 8	Flexores, Flexor Profundo

Tabla 3.3. Relación de Movimientos-Canal

Movimientos	Canales
Desviación Radial	3, 4 y 5
Desviación Cubital	0, 1 y 2
Flexión de Codo	3
Pinza Gruesa	2 y 4
Pinza Fina	1 y 2
Soltar	0 y 3
Flexión de Muñeca	6, 6, 7 y 0
Extensión de Muñeca	2, 3 y 4

El diagrama de la figura 3.13 resume el proceso de la obtención de información del participante.

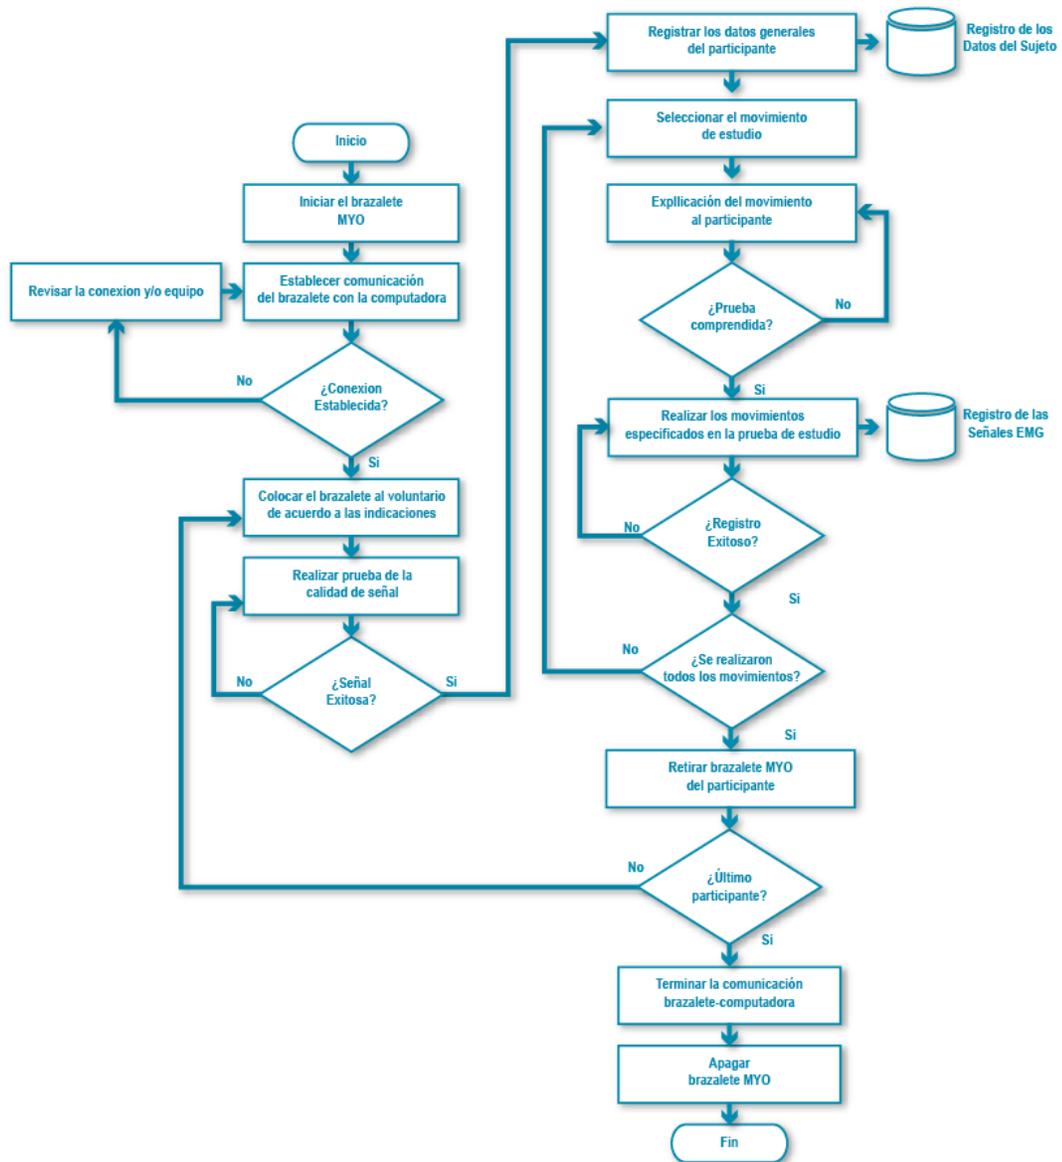


Fig. 3.13. Diagrama de flujo que describe el proceso de obtención de datos.

3.4 Extracción de Características

La identidad de una señal EMG que se origina en el músculo, a veces se puede llegar a perder debido a la mezcla de varias señales de ruido o artefactos. Los atributos de una señal EMG dependen de la estructura interna del sujeto, como formación de piel, flujo de sangre, nivel de grasa, grosor de la piel, etc. también existen diferentes causas de ruido conocidas que pueden ser tratadas con un filtro pasa bandas, tales como el ruido electromagnético, cross talk, ruido interno; Estos tipos de ruido producen diferentes tipos de señales ruidosas que pueden dificultar la captura de la señal EMG original (Chowdhury, R. et al., 2013) pero pueden ser tratados con un filtro notch o similares. Pero para el ruido causado en frecuencias desconocidas se proponen los siguientes métodos.

3.4.1 Transformada de Fourier (FT)

El análisis del espectro de una señal involucra la descomposición de una señal a sus componentes de frecuencia. Entre las técnicas de análisis de espectro, la FT es considerada una de las mejores transformaciones entre dominio de frecuencia y tiempo (Canal, M. R. 2010) debido a que nos facilita llevar una señal en dominio de tiempo a dominio de frecuencia y su transformada inversa nos facilita volver al dominio de tiempo.

Es expresada como la ecuación 3.1 y su inversa como 3.2

$$X(k) = \sum_{n=0}^{N-1} x(n) \cdot W_N^{kn}, \quad (3.1)$$

$$X(n) = \frac{1}{N} \sum_{k=0}^{N-1} x(k) \cdot W_N^{-kn}, \quad (3.2)$$

donde $W_N = e^{-j(\frac{2\pi}{N})}$ y $N =$ longitud de $[x(n)]$.

La Transformada Rápida de Fourier (FFT) es una versión más rápida de la FT. La FFT es el algoritmo que se utiliza para realizar la DFT de una forma eficiente

y rápida (Cortes et al., 2007). La figura 3.14 muestra una señal en su dominio de tiempo y frecuencia usando la FFT.

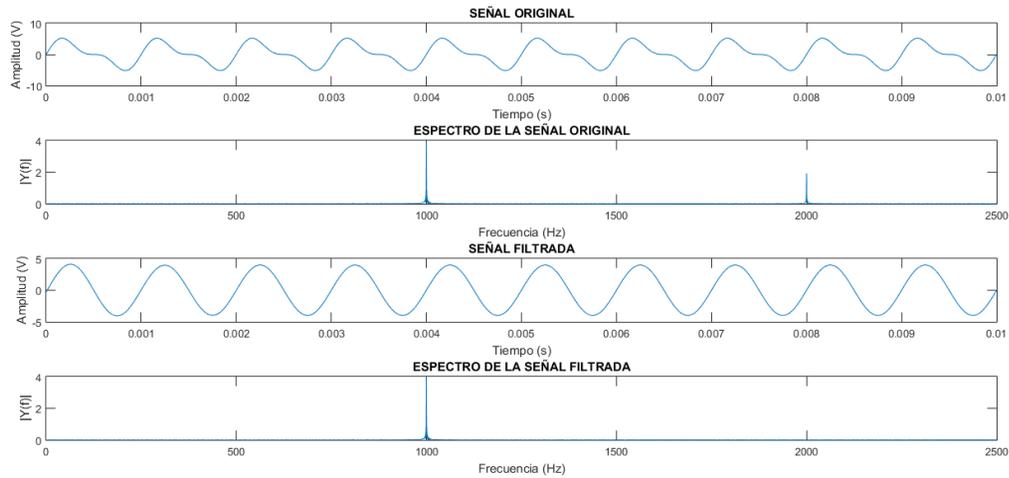


Fig. 3.14. Graficas de una señal antes y después de su filtrado y su espectro usando FFT
(Creación Propia)

3.4.2 Transformada Wavelet (WT)

La WT ha demostrado ser una herramienta de análisis de señales en dominio de tiempo y frecuencia. Existen varios tipos, o familias, de wavelets que pueden servir para la caracterización de la señal, pero la selección apropiada de una de estas para el análisis de nuestras señales es de vital importancia. Dependiendo de la bio-signal que vaya a ser analizada se puede elegir la wavelet madre (Gandhi, T., Panigrahi, B. K., & Anand, S. 2011).

La WT es definida (3.3) como un análisis multiresolución de una función $f(t)$, el cual descompone la señal original en un conjunto de funciones $W_f(s, \tau)$ que forman los coeficientes wavelets.

$$W_f(s, \tau) = \int f(t) \Psi_{s, \tau}(t) dt \quad (3.3)$$

Las Wavelets son generadas a partir de la traslación y cambio de escala de una misma función wavelet $\Psi_{s,\tau}(t)$, llamada la “Wavelet Madre”, y se define en 3.3.

$$\Psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \Psi\left(\frac{t - \tau}{s}\right) \quad (3.4)$$

Donde s representa el factor de escala y τ es el factor de traslación.

3.4.3 Wavelet Denoising

Como se mencionó anteriormente elegir la wavelet madre es crucial para una correcta eliminación del ruido en la señal, esto es un problema que depende de muchos factores, como el tipo de la señal, así como sus características. Chowdhury presenta una tabla con los diferentes tipos y subtipos de wavelets. La figura 3.15 muestra una señal EMG en bruto y su comparación sin ruido por la función wavelet db4.

Tabla 3.4. Lista de las 324 funciones wavelet agrupadas en 15 tipos o familias (Traducida de Chowdhury, R.et al., 2013)

Familia de la Wavelet	Subtipo de Wavelet	#
Haar	db1	1
Daubechies	db2-db45	2-45
Coiflet	coif1-coif5	46-50
Morlet	morl	51
Morlet Discreta Compleja	cmor	52-147
Meyer Discreta	dmey	148
Meyer	meyr	149
Sombrero Mexicano	mexh	150
Shannon	shan	151-200
"Frequency B-spline"	fbsp	201-260
Gausiana	gaus	261-267
Gausiana Biortogonal Compleja	cgaus	268-275
Biortogonal	bior	276-290
Biortogonal Inversa	rbio	291-305
Symlet	sym	306-324

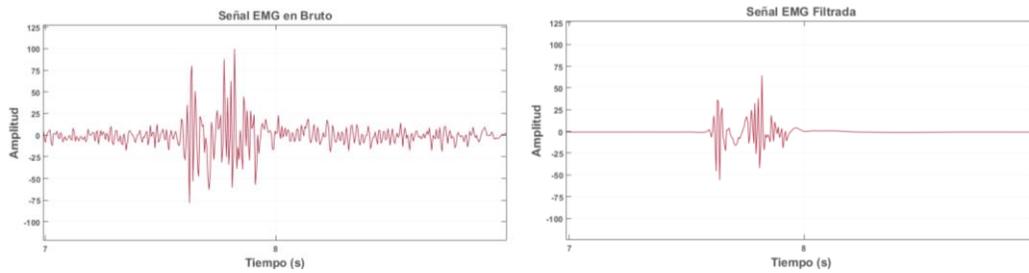


Fig. 3.15. Señal original y con eliminación de ruido utilizando wavelet denoising (Creación Propia)

3.4.4 Caracterización de las señales

La extracción de características es un método para obtener información valiosa de las señales EMG e ignorar interferencias de las señales, así como segmentos no deseados de la señal. Las características de la señal pueden ser clasificadas en dominio en tiempo y dominio en frecuencia, para este trabajo se utilizaron las características en dominio del tiempo. Las siguientes funciones fueron obtenidas del recopilatorio de Phinyomark, A., 2012. Para todas las ecuaciones x_i representa la señal EMG en un segmento i y N denota la longitud de la señal EMG.

3.4.5 Integrated EMG (IEMG)

Se usa normalmente como un índice de detección de inicio en el reconocimiento EMG sin patrones y en aplicaciones clínicas (Huang & Chen, 1999; Merletti, 1996). La definición de IEMG es la sumatoria de los valores absolutos de la amplitud de la señal EMG, que puede ser expresada como:

$$IEMG = \sum_{i=1}^N |x_i|. \quad (3.4)$$

3.4.6 Mean Absolute Value (MAV)

Es una de las características más utilizadas usadas en análisis de señales EMG (Hudgins et al., 1993; Zardoshti-Kermani et al., 1995). MAV es un promedio del valor absoluto de la amplitud de la señal EMG en un segmento definido como:

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i|. \quad (3.5)$$

3.4.7 Modified Mean Absolute Value type 1 and type 2 (MAV1, MAV2)

Estas son una expansión de la característica MAV (Oskoei & Hu, 2008; Phinyomark et al., 2009a). En MAV1 (Ec. 3.6) la función de ventana ponderada w_i se asigna a la ecuación para mejorar la robustez de la característica MAV, mientras que MAV2 (Ec. 3.7) la función de ventana ponderada que se asigna a la ecuación es de forma continua, mejorando la suavidad de la función. Las ecuaciones son las siguientes:

$$MAV1 = \frac{1}{N} \sum_{i=1}^N w_i |x_i|; \quad (3.6)$$

$$w_i \begin{cases} 1, & \text{si } 0.25N \leq i \leq 0.75N \\ 0.5 & \end{cases}$$

$$MAV2 = \frac{1}{N} \sum_{i=1}^N w_i |x_i|; \quad (3.7)$$

$$w_i \begin{cases} 1, & \text{si } 0.25 \leq i \leq 0.75N \\ \frac{4i}{N}, & \text{si } i < 0.25 \\ \frac{4(i-N)}{N}, & \end{cases}$$

3.4.8 Simple Square Integral (SSI)

SSI usa la energía de la señal EMG como característica (Du & Vuskovic, 2004). Es la suma de los valores al cuadrado de la amplitud de la señal EMG. Se le conoce como índice de energía (energy index).

$$SSI = \sum_{i=1}^N x_i^2. \quad (3.8)$$

3.4.9 Variance of EMG (VAR)

La varianza es definida como un promedio de los valores al cuadrado de la desviación de la variable, sin embargo, la varianza de la señal EMG es muy cercana a cero por lo tanto la varianza de la señal EMG también puede ser definida como:

$$VAR = \frac{1}{N-1} \sum_{i=1}^N x_i^2. \quad (3.9)$$

3.4.10 Absolute Value of the 3rd, 4th, and 5th Temporal Moment (TM3, TM4, TM5)

El momento temporal es un análisis estadístico propuesto por Saridis, G. N., & Gootee, T. P. (1982) para ser usado en el control de una prótesis de brazo. La definición de cada ecuación es definida como:

$$TM3 = \left| \frac{1}{N} \sum_{i=1}^N x_i^3 \right|; \quad (3.10)$$

$$TM4 = \frac{1}{N} \sum_{i=1}^N x_i^4; \quad (3.11)$$

$$TM5 = \left| \frac{1}{N} \sum_{i=1}^N x_i^5 \right|. \quad (3.12)$$

3.4.11 Root Mean Square (RMS)

RMS, es otra característica utilizada en la señal EMG, se ha utilizado ya en trabajos previos (Boostani & Moradi, 2003; Kim et al., 2011). Es modelada como un proceso aleatorio gaussiano de amplitud modulada que se relaciona con la fuerza constante y la contracción sin fatiga. Es expresada como:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}. \quad (3.13)$$

3.4.12 v-Order (VO)

Es un detector no lineal que implícitamente estima la fuerza de contracción del músculo como m . Es definida a partir de un modelo matemático funcional de la generación de la señal EMG (Tkach et al., 2010; Zardoshti-Kermani et al., 1995). VO es definida como:

$$VO = \left(\frac{1}{N} \sum_{i=1}^N x_i^v \right)^{\frac{1}{v}}. \quad (3.14)$$

De acuerdo con Tkach et al. (2010) y Zardoshti-Kermani et al. (1995) el valor óptimo para v es 2.

3.4.13 Log Detector (LOG)

Este atributo provee un estimado de la información de la contracción del músculo. (Tkach et al., 2010; Zardoshti- Kermani et al., 1995). Sin embargo, la definición del detector no lineal se cambia para basarse en logaritmo. dando como resultado LOG que es definida como:

$$LOG = e^{\frac{1}{N} \sum_{i=1}^N \log(|x_i|)}. \quad (3.15)$$

3.4.14 Waveform Length (WL)

WL es una medida de la complejidad de la señal EMG (Hudgins et al., 1993; Oskoei & Hu, 2008). Es definida como la longitud acumulada de la forma de onda sobre el segmento de tiempo: Es calculada como:

$$WL = \sum_{i=1}^{N-1} |x_{i+1} - x_i|. \quad (3.16)$$

3.4.15 Average Amplitude Change (AAC)

AAC es un equivalente a WL, salvo que la longitud de onda se encuentra promediada (Fougner, A. L., 2007). Por definición, este atributo divide WL por el valor de $N - 1$.

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

3.4.16 Difference Absolute Standard Deviation Value (DASDV)

Aunque parezca similar a una característica de RMS, DASDV Es una desviación estándar de la longitud de onda (Kim et al., 2011) y es definida como:

$$DASDV = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (x_{i+1} - x_i)^2}. \quad (3.18)$$

3.4.17 Zero Crossing (ZC)

Es el número de veces que los valores de la amplitud de la señal EMG cruzan el nivel de amplitud en cero. Para evitar fluctuaciones de bajo voltaje o ruido de fondo, la condición umbral es implementada y el cálculo se define como:

$$ZC = \sum_{i=1}^{N-1} [\text{sgn}(x_i \times x_{i+1}) \cap |x_i - x_{i+1}| \geq \text{umbral}]; \quad (3.19)$$

$$\text{sgn}(x) = \begin{cases} 1, & \text{si } x \geq \text{umbral} \\ 0, & \text{de otra manera} \end{cases}$$

3.4.18 Myopulse Percentage Rate (MYOP)

MYOP es un valor promedio de salida definido como uno cuando el valor absoluto de la señal EMG excede el valor del umbral predefinido (Fougner, 2007; Philipson, 1987). Matemáticamente es calculada como:

$$MYOP = \frac{1}{N} \sum_{i=1}^N [f(x_i)]; \quad (3.20)$$

$$f(x_i) = \begin{cases} 1, & \text{si } x \geq \text{umbral} \\ 0, & \text{de otra manera} \end{cases}$$

3.4.19 Willison Amplitude (WAMP)

Es el número de veces que resulta de la diferencia entre la amplitud de la señal EMG entre dos segmentos contiguos que excede un umbral predefinido. Además, está relacionado a la actuación de los MUAPs y la fuerza de contracción muscular. Se define como:

$$WAMP = \sum_{i=1}^{N-1} [f(|x_i - x_{i+1}|)]; \quad (3.21)$$

$$f(x_i) = \begin{cases} 1, & \text{si } x \geq \text{umbral} \\ 0, & \text{de otra manera} \end{cases}$$

3.4.20 Reducción de Dimensionalidad

Si la información que un algoritmo debe de procesar es muy grande y muchas variables y atributos resultan ser redundantes, la información necesita una reducción de atributos (Guyon, I., & Elisseeff, A., 2003). La reducción de dimensionalidad (Feature Reduction and Selection) es un concepto necesario en ML, como se muestra en la siguiente figura, la esta reducción es necesaria por varios motivos, entre uno de ellos que nuestro algoritmo sea más rápido.

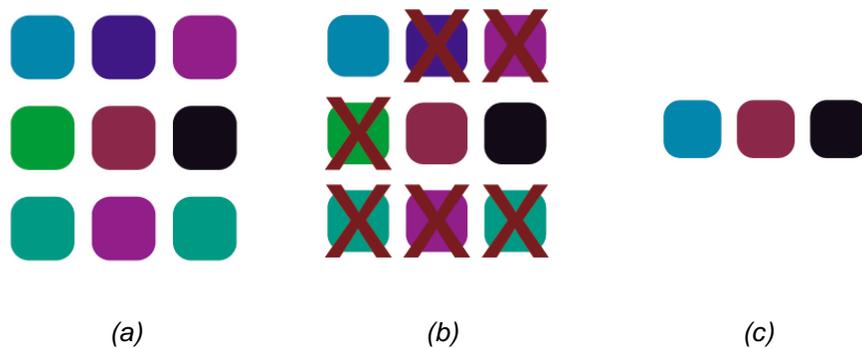


Fig. 3.16. Reducción de Dimensionalidad, en la figura a se puede apreciar un conjunto de atributos completos, en la figura b, se eliminan aquellos que sean inciertos, indiscernibles de otros o puedan causar ruido en nuestro entrenamiento, en la figura c se muestran las características elegidas para el entrenamiento. (Creación Propia)

3.4.21 Rough Sets (RS)

Rough Sets (RS) es una teoría desarrollada por Zdzislaw Pawlak en principios de 1980 y en sus propias palabras (Pawlak, Z., 1982). es de importancia en algunas ramas de la IA, tales como el razonamiento inductivo, clasificación automática, reconocimiento de patrones, aprendizaje automático, etc. El objetivo principal de RS es lidiar con la indiscernibilidad (Forrest, P. 1996) de los atributos de los componentes del sistema de información $A = (U, A)$ (Tabla 3.5).

Tabla 3.5. Ejemplo de un sistema de información, donde hay siete casos u objetos y dos atributos: edad y puntuación de la extremidad inferior del motor (LEMS) (Traducido de Komorowski, J. et al., 1999).

	Edad	LEMS
X1	16-30	50
X2	16-30	0
X3	31-45	1-25
X4	31-45	1-25
X5	46-60	26-49
X6	16-30	26-49
X7	46-60	26-49

Un sistema de decisión $A = (U, A \cup \{d\})$ involucra un atributo de decisión donde $d \notin A$, como se muestra en la tabla siguiente:

Tabla 3.6. El atributo de decisión permite tomar decisiones basándonos en la información del sistema de información (Traducido de Komorowski, J. et al., 1999).

	Edad	LEMS	Camina
X1	16-30	50	Si
X2	16-30	0	No
X3	31-45	1-25	No
X4	31-45	1-25	Si
X5	46-60	26-49	No
X6	16-30	26-49	Si
X7	46-60	26-49	No

RS nos ayuda a reducir el sistema de información mediante conjuntos indiscernibles, por ejemplo, el caso X3 y X4 que son similares entre ellos y no hay una diferencia distinguible, pero si el conjunto de información cuenta con datos como X5 y X7 que, aunque no hay diferencia en sus atributos de condición, su atributo de decisión es diferente, a este conjunto se le conoce como un conjunto aproximado (Rough Set).

3.4.22 Análisis de Componentes Principales (PCA)

El objetivo del Análisis de Componentes Principales (PCA, por sus siglas en inglés) es reducir la dimensionalidad de un conjunto de datos, con la menor pérdida de información posible, utilizando la matriz de covarianza (Ecuaciones 7.1 y 7.2). Y aunque es una técnica que se desarrolló antes de la segunda guerra mundial, sigue siendo utilizada ampliamente (Maćkiewicz, A., & Ratajczak, W., 1993). El siguiente diagrama de bloques resume el proceso computacional del PCA.

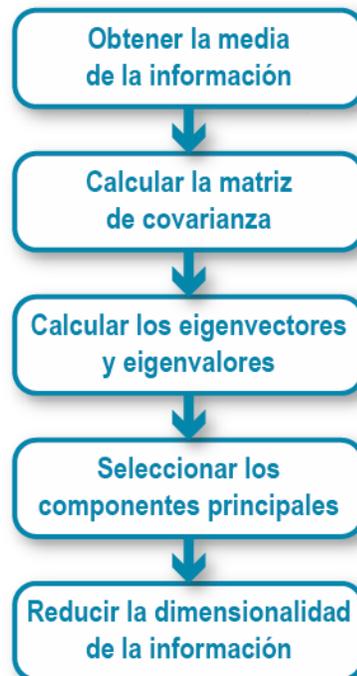


Fig. 3.17. Diagrama de bloques de PCA

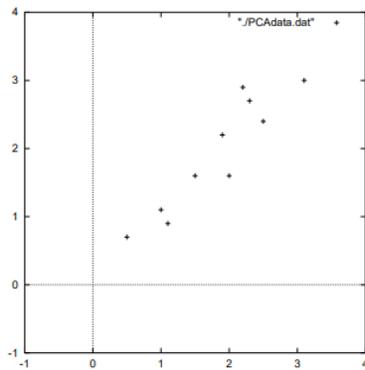
Las fórmulas de las matrices de covarianza se definen como:

$$\mathbf{cov}(\mathbf{X}) = \frac{\mathbf{X}^T \mathbf{X}}{n-1}, \quad (3.22)$$

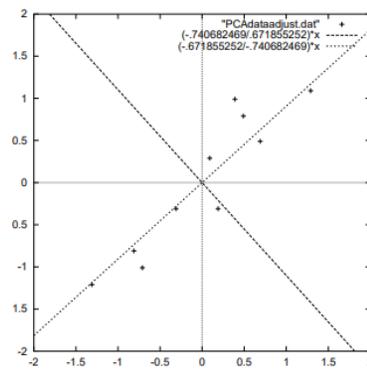
$$\mathbf{cov}(\mathbf{X}) \mathbf{P}_a = \lambda_a \mathbf{P}_a. \quad (3.23)$$

Donde λ_a es el valor propio asociado al vector propio \mathbf{P}_a

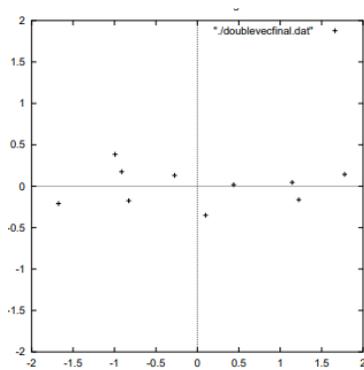
El proceso visualmente se puede apreciar en las figuras 3.18 (a, b, c y d):



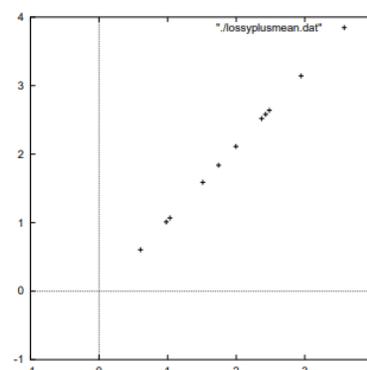
(a)



(b)



(c)



(d)

Fig. 3.18. (a) Grafico original de los atributos de los datos. (b) Grafico de los datos normalizados con los eigenvectores de la matriz de covarianza superpuesta. (c) La grafica de los datos aplicando PCA. (d) Reconstrucción de los datos usando un eigenvector (Gráficos por Smith, L. I., 2002).

3.5 Clasificación

Una vez que los datos se encuentran listos son aptos para ser trabajados en un algoritmo de ML, como los que se citan a continuación. Un algoritmo clasificador tiene la función de determinar a qué grupo o cluster pertenece un nuevo dato ingresado. Un grupo es nuestro sistema de información particionado en uno o varios

grupos, la finalidad es particionar la información de tal manera que los grupos formados compartan características y funcionen para predecir valores futuros. En la figura 3.19 se puede observar un sistema de información graficado en dos dimensiones.

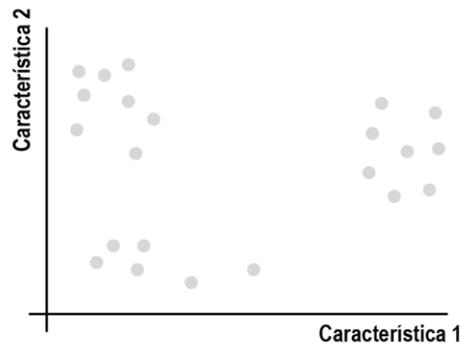


Fig. 3.19. Sistema de información graficada sin grupos definidos (Creación Propia).

3.5.1 K-Media (K-Means Clustering)

K-Medias (Hartigan, J. A., & Wong, M. A., 1979) es un algoritmo no supervisado y será de utilidad para definir los grupos del sistema de información. Intenta encontrar el centro de cada grupo hasta definir k grupos completos (Fig 3.20)

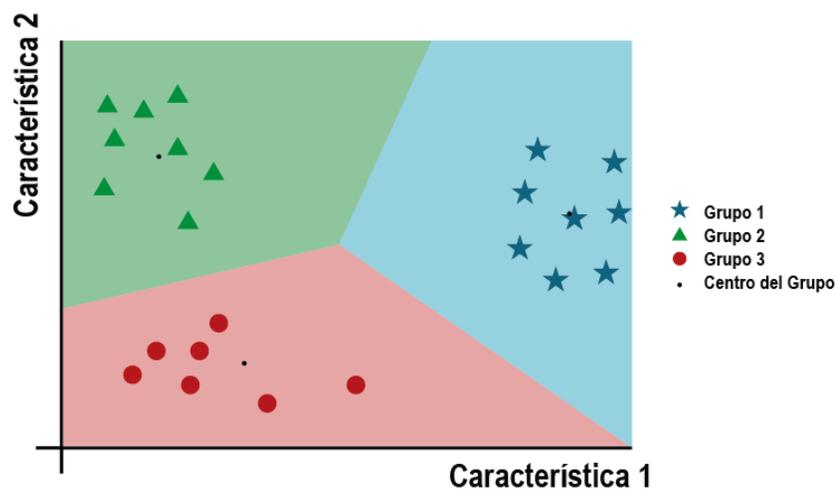


Fig. 3.20. Agrupamiento de datos con su centroide calculado, donde se obtienen tres grupos resultantes (Creación Propia).

Una de las ventajas de este algoritmo es que no necesita tener previo conocimiento del valor de sus grupos, en contraparte una de sus desventajas es que el valor de k debe ser ingresado manualmente para que el algoritmo sepa cuantos grupos va a buscar. Debido a estas deficiencias se han hecho varias propuestas del algoritmo como K-Medoids (Park, H. S., & Jun, C. H., 2009), Fuzzy C Means (Bezdek, J. C., Ehrlich, R., & Full, W., 1984), etc.

3.5.2 Vecino más cercano (kNN)

Es un algoritmo de agrupamiento supervisado bastante conocido y fácil de entender; para entrenar al modelo solo hace falta tener la información almacenada. En la versión más simple del algoritmo calcula la mayoría de un total de puntos, es el valor de k , más cercanos al punto al que buscamos predecir su valor, la figura 3.21 ilustra un ejemplo gráfico del algoritmo.

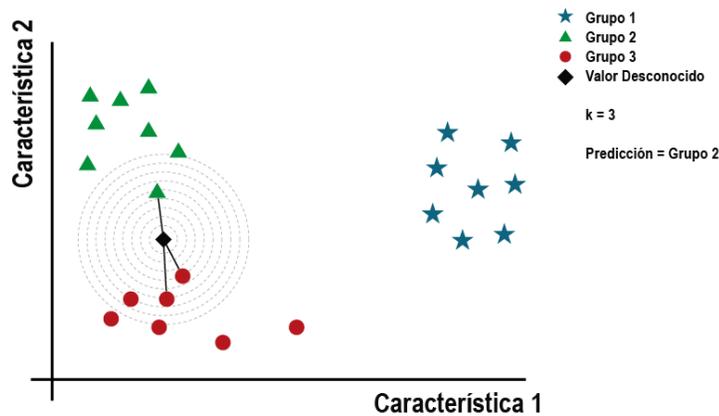


Fig. 3.21. Predicción del valor desconocido utilizando 3 vecinos más cercanos (Creación Propia).

Se considera un algoritmo de aprendizaje automático supervisado, debido a que, desde un inicio, los grupos ya han sido predefinidos. El único elemento con un

valor desconocido es el valor ingresado para comprobar su pertenencia. Las ventajas de este algoritmo es que es fácil de entender, implementar y es computacionalmente rápido. Las desventajas con las que cuenta son que, si se desconocen los valores de los grupos, el algoritmo no puede ser ejecutado, y debido a que una de las variables es el número de vecinos a seleccionar, este puede arrojar diferentes resultados dependiendo del valor asignado, este último ejemplo se ilustra en la imagen siguiente.

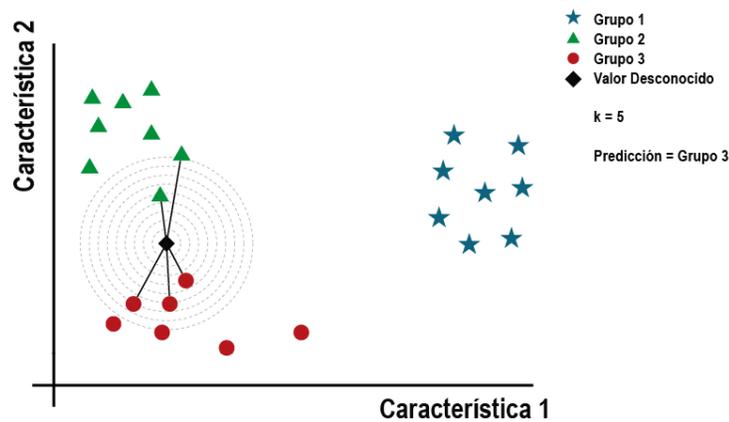


Fig. 3.22. La predicción del valor desconocido cambia si utilizamos 5 vecinos en lugar de 3 (Creación Propia).

No obstante, estos algoritmos siguen siendo utilizados para resolver problemas complejos (Chou, K. C., & Shen, H. B., 2006, Kolahtouzan, M., & Shahabi, C., 2004) y cada vez se proponen nuevas versiones de ellos (Zhang, M. L., & Zhou, Z. H., 2007).

3.6 Evaluación de Desempeño

La evaluación de desempeño calcula que tan buenos resultados arroja nuestro algoritmo. Es importante aclarar que un algoritmo difícilmente será siempre 100%

preciso y/o exacto, pero para medir su eficacia se cuenta con las siguientes herramientas.

3.6.1 Exactitud, Sensibilidad y Especificidad (Accuracy, Sensitivity and Specificity)

Para calcular cada uno de estos valores necesitamos definir algunos valores primero:

- Verdadero Positivo (VP) = el número de casos correctamente identificados como positivos.
- Falso Positivo (FP) = el número de casos incorrectamente identificados como positivos.
- Verdadero Negativo (VN) = el número de casos correctamente identificados como negativos.
- Falso Negativo (FN) = el número de casos incorrectamente identificados como negativos.

La siguiente imagen representa un ejemplo de la situación explicada:



Fig. 3.23 Casos de ejemplo para valores de una hipótesis (Creación Propia).

Baratloo, A. et al., definen la sensibilidad, especificidad y exactitud de la siguiente manera:

La exactitud de un experimento es la habilidad para determinar el número de casos verdaderos correctamente y se describe con la fórmula 3.24.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.24)$$

La sensibilidad de un experimento es la habilidad para determinar el número de casos verdaderos positivos correctamente y se describe con la fórmula 3.25.

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (3.25)$$

La especificidad de un experimento es la habilidad para determinar el número de casos verdaderos negativos correctamente y se describe con la fórmula 3.26

$$\text{Specificity} = \frac{TN}{TN + FP} \quad (3.26)$$

4. RESULTADOS Y DISCUSIÓN

4.1 Experimentación

Como se explicó anteriormente, dentro de la metodología, cada participante ejecuto el movimiento 5 veces en un intervalo de 3 segundos iniciando desde el segundo 1 el experimento fue realizado de esta manera con la finalidad de poder determinar el momento en el que el movimiento empieza y posteriormente segmentar la señal. Como resultado de la recolección de señales se obtuvieron 160 señales por participante, diez movimientos por ambos brazos por los ocho canales ($10 * 8 * 2 = 160$). En la figura 4.1 se puede observar como un conjunto de ocho señales corresponden a un solo movimiento.

De la misma figura 4.1 se pueden observar la comparación de señales para un mismo movimiento de flexión, es observable que, aunque es el mismo movimiento los canales con mayor actividad son diferentes, para el brazo izquierdo son los canales 1, 5, 6, 7 y 8 mientras que los canales con mayor actividad para el brazo derecho son 1, 2, 3, 7 y 8, esta característica es imitada por los demás movimientos por lo que se tomó la decisión de separar los movimientos para su posterior clasificación como movimiento realizado por el brazo derecho o izquierdo.

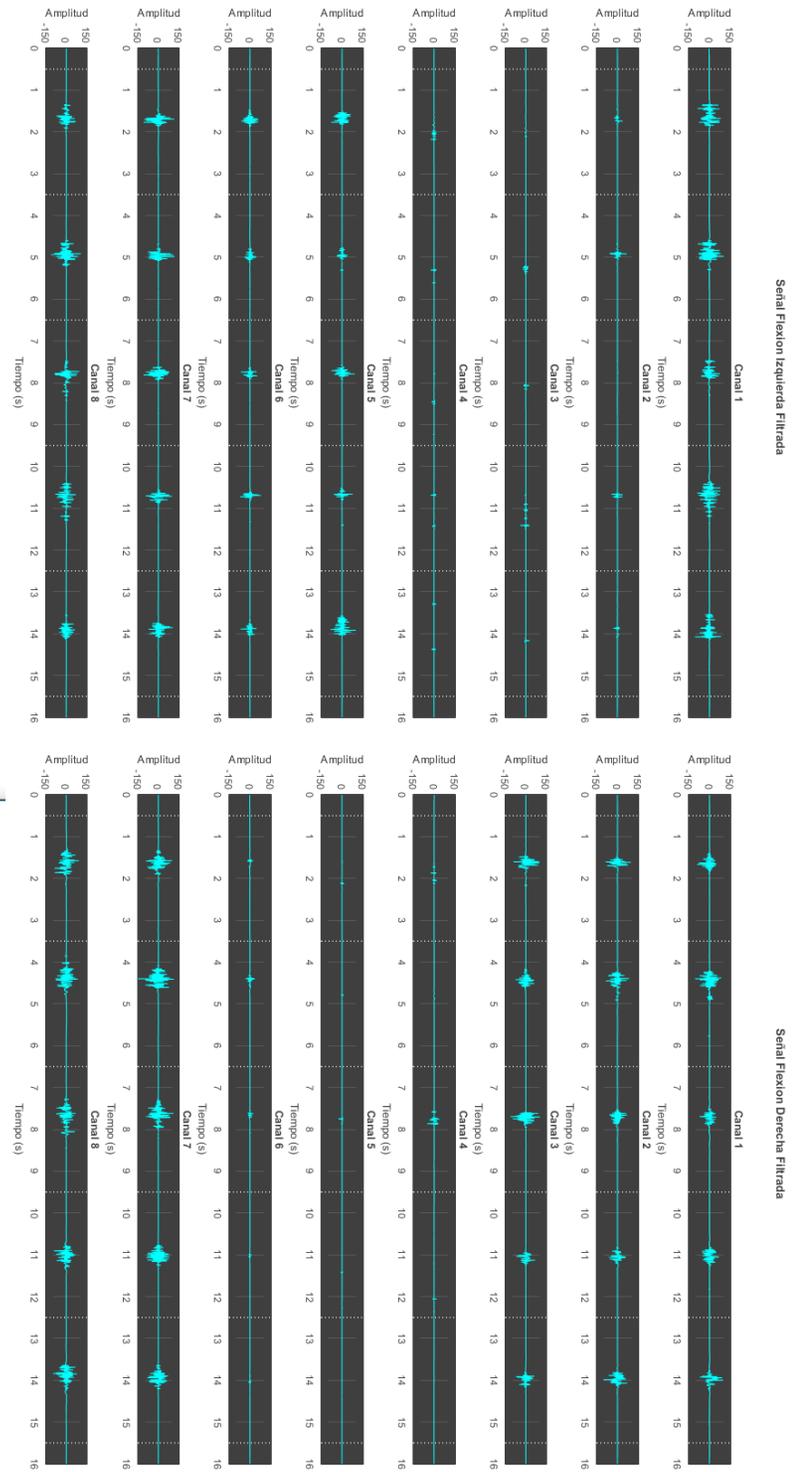


Fig. 4.1 Señales filtradas de los ocho canales para el movimiento flexión para ambos brazos.

Nuestro sistema de información fue almacenado en una matriz S y la información de la señal, tal como participante, movimiento, mano, fueron almacenados en una matriz I la figura 4.2 ejemplifica estos valores.

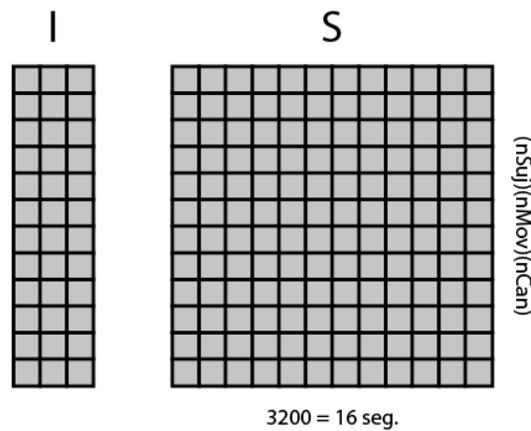


Fig. 4.2. La matriz S almacena los valores de la señal mientras la matriz I almacena las características para su posterior entrenamiento y decisión.

Posteriormente cada señal fue dividida en cinco partes cada una con tres segundo de duración (figura 4.3), dado que conocemos la duración e inicio de cada señal, la segmentación se realizó en los segundos 0.5, 3.5, 6.5, 9.5 y 12.5.

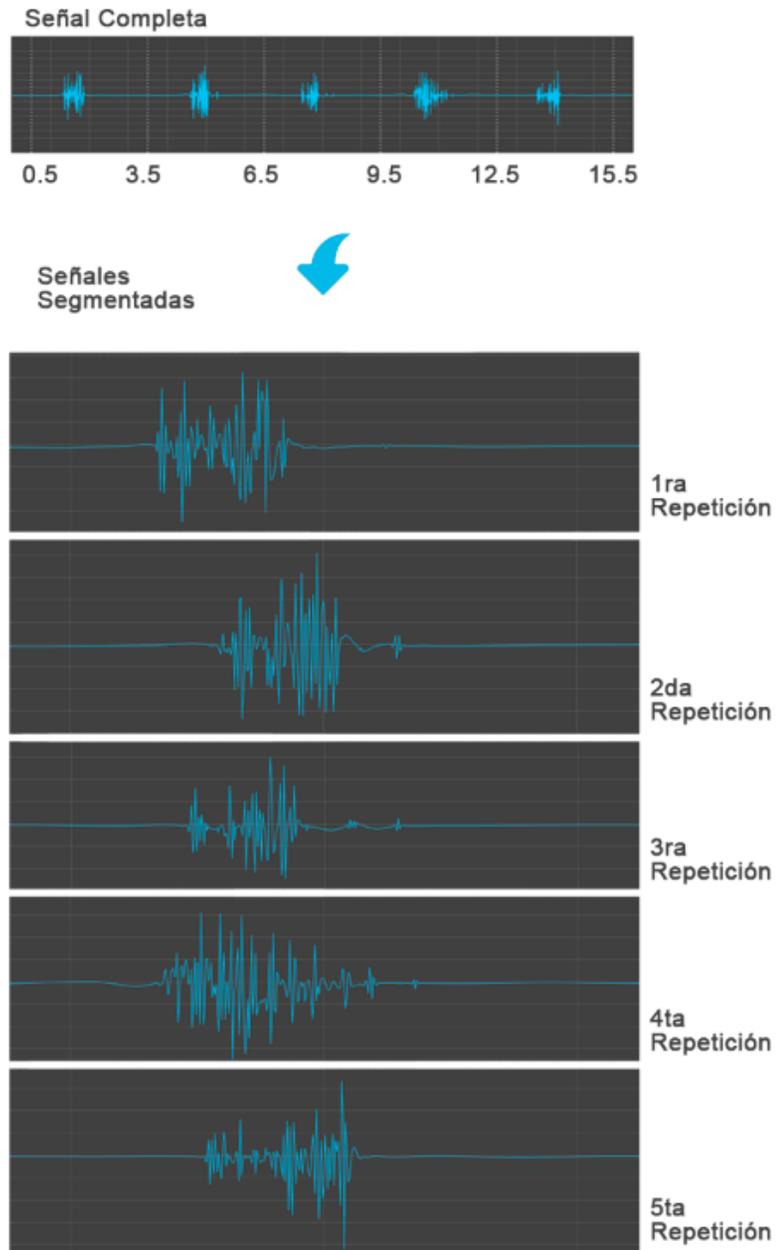


Fig. 4.3. Proceso de segmentación de la señal.

Este cambio genera que nuestro sistema de información crezca actualizando la matriz S e I (Figura 4.4). El siguiente paso es calcular las características y se

genera un nuevo set de información llamado F así como un índice correlacionado con la señal correspondiente.

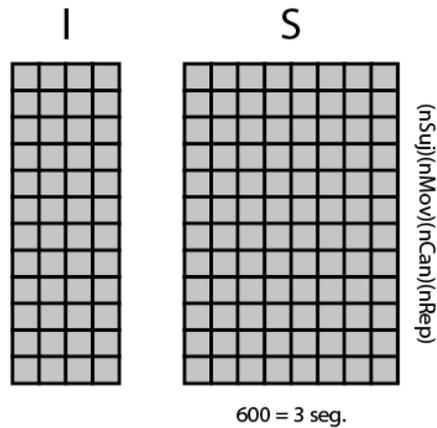


Fig. 4.4. La matriz S ahora almacena cada señal segmentada, mientras que la matriz I almacena también a que repetición corresponde.

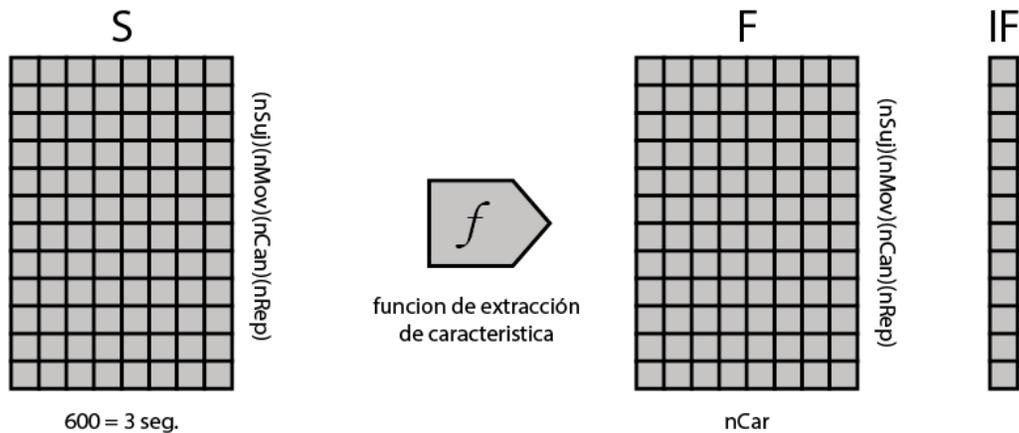


Fig. 4.5. La matriz F almacena las características extraídas de cada señal mientras que la matriz IF almacena la información acerca de la señal correspondiente.

Después de extraer las características para cada señal el sistema de información se separó en dos grupos, un grupo para entrenar el modelo y otro grupo

para corroborar el mismo (Figura 4.6). Para el experimento se utilizó la relación 80-20 donde 80% del sistema de información fue usado para entrenamiento mientras que el 20% restante fue utilizado para pruebas, esto con la finalidad de no caer en un error de sobreajuste (overfitting).

Con cada ejecución del entrenamiento, los valores eran seleccionados mediante un valor pseudoaleatorio, (figura 4.5), esta ejecución nos aseguraba variedad en las señales elegidas para el modelo de entrenamiento y de pruebas, esto nos permitió homogenizar los resultados y demostrar que la información resultante no sufriera de un sesgo estadístico. La tabla 4.1 muestra la organización de las características extraídas en la matriz.

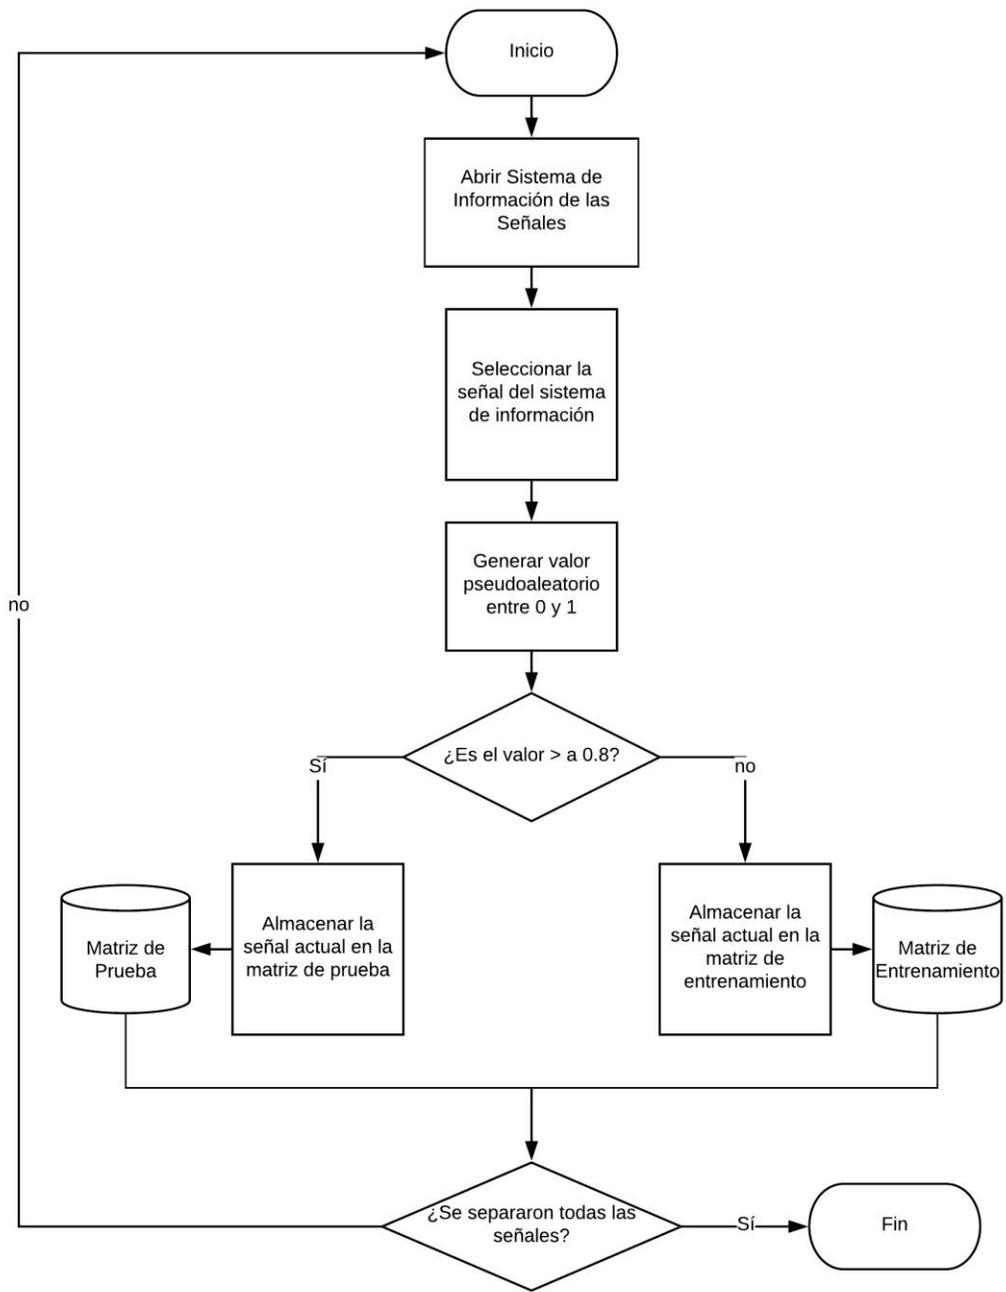


Fig. 4.6. Separación del sistema de información de las señales, el grupo de entrenamiento y el grupo de prueba.

Tabla 4.1. Tabla de resultados de extracción de características

	AAC	DASDV	IEMG	LD	MAV	MAV1	MAV2	MTW	MYOP	PF	RMS	SQI	SSC	TM3	TM4	TM5	VAR	VO	WAMP	WL	ZC	
Suj 1, Mov 1, Can 1, Rep 1																						
Suj 1, Mov 1, Can 1, Rep 2																						
...																						
Suj 1, Mov 1, Can 1, Rep 5																						
Suj 1, Mov 1, Can 2, Rep 1																						
...																						
Suj 1, Mov 1, Can 8, Rep 5																						
...																						
Suj 1, Mov 2, Can 1, Rep 1																						
...																						
Suj 1, Mov 2, Can 8, Rep 5																						
...																						
Suj N, Mov 20, Can 8, Rep 5																						
...																						

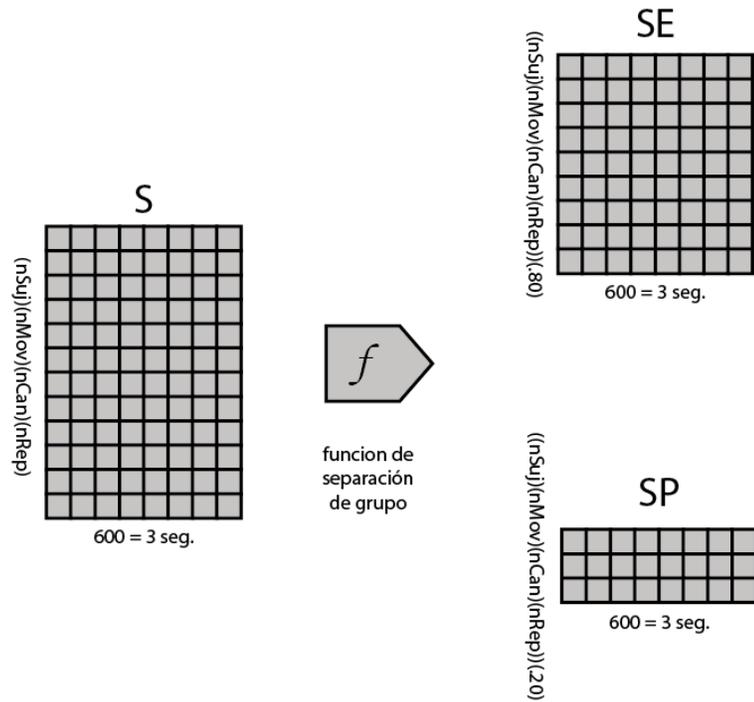


Fig. 4.7. El sistema de información original fue separado en dos grupos, el grupo de entrenamiento y el grupo de pruebas.

La matriz de entrenamiento se utiliza para calcular los centroides de los pesos de las características, este cálculo se basa en los centroides y grupos explicados en los algoritmos de agrupación (Ec. 4.1). Para este proceso se utilizaron los ocho canales de cada característica (Figura 4.7 y Tabla 4.2).

$$Pf = \frac{\sum_{n=0}^N nf}{N}, \tag{3.1}$$

donde Pf representa el peso del centroide de la característica y N el total de características.

Este proceso se repitió por cada característica arrojando pesos diferentes para cada una (fig. 4.8).

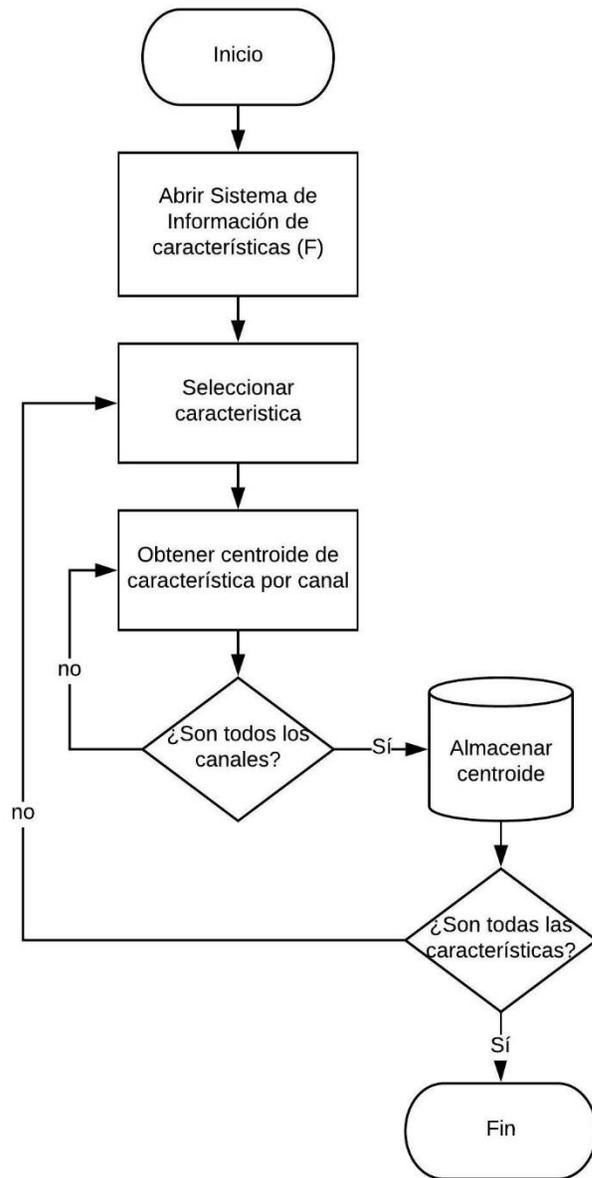


Fig. 4.8. Diagrama de flujo para la obtención de pesos de los centroides de las características.

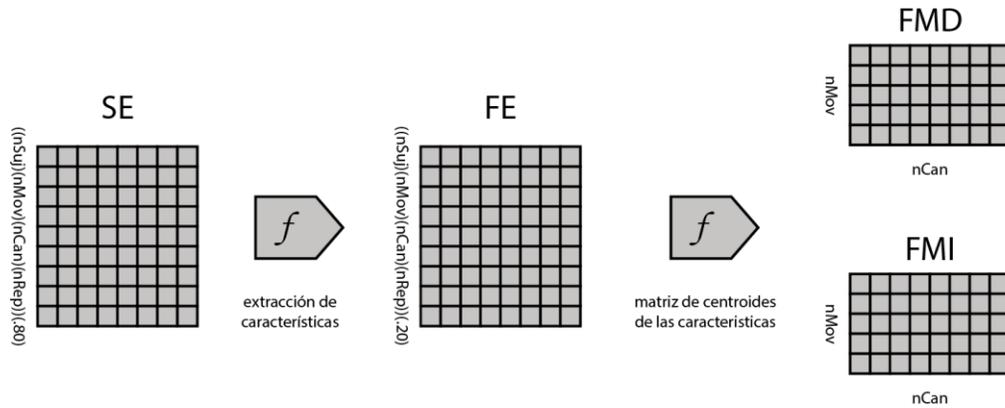


Fig. 4.9. De la matriz de señales de entrenamiento (SE) se extraen sus características (FE) y se calculan sus centroides por cada brazo (FMD y FMI).

Tabla 4.2. Tabla de centroides resultantes por cada brazo para una sola característica.

Movimientos del Brazo Derecho	MOVIMIENTO	CAN 1	CAN 2	CAN 3	CAN 4	CAN 5	CAN 6	CAN 7	CAN 8
	Posicion Inicial	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
	Pronacion	0.010	0.020	0.045	0.009	0.009	0.014	0.062	0.032
	Supinacion	0.014	0.021	0.028	0.007	0.002	0.002	0.012	0.014
	Extension	0.060	0.085	0.186	0.232	0.241	0.083	0.038	0.041
	Flexion	0.260	0.085	0.015	0.017	0.008	0.028	0.237	0.258
	Desviacion Cubital	0.200	0.185	0.294	0.024	0.007	0.002	0.016	0.054
	Desviacion Radial	0.018	0.015	0.020	0.030	0.040	0.014	0.038	0.026
	Pinza Fina	0.011	0.002	0.009	0.008	0.008	0.001	0.008	0.014
	Pinza Gruesa	0.166	0.371	0.068	0.026	0.077	0.020	0.032	0.128
	Expansion	0.056	0.034	0.063	0.053	0.033	0.003	0.015	0.041

Movimientos del Brazo Izquierdo	MOVIMIENTO	CAN 1	CAN 2	CAN 3	CAN 4	CAN 5	CAN 6	CAN 7	CAN 8
	Posicion Inicial	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.001
	Pronacion	0.069	0.026	0.009	0.010	0.036	0.023	0.009	0.029
	Supinacion	0.010	0.002	0.001	0.007	0.042	0.017	0.014	0.012
	Extension	0.036	0.083	0.237	0.241	0.134	0.045	0.034	0.033
	Flexion	0.193	0.010	0.009	0.020	0.018	0.051	0.202	0.260
	Desviacion Cubital	0.006	0.002	0.008	0.044	0.237	0.118	0.124	0.027
	Desviacion Radial	0.015	0.016	0.040	0.023	0.022	0.016	0.023	0.032
	Pinza Fina	0.007	0.003	0.008	0.009	0.008	0.004	0.013	0.015
	Pinza Gruesa	0.025	0.024	0.066	0.029	0.089	0.403	0.217	0.127
	Expansion	0.005	0.003	0.028	0.057	0.054	0.036	0.056	0.024

Finalmente se ingresaron las señales y características del sistema de información de pruebas al modelo generado para calcular su precisión, sensibilidad y especificidad.

El proceso para clasificar una señal de entrada al modelo generado se basa en una modificación del algoritmo KNN, donde se compara la distancia de los centroides de los movimientos entrenados contra el movimiento de prueba (figura 4.31).

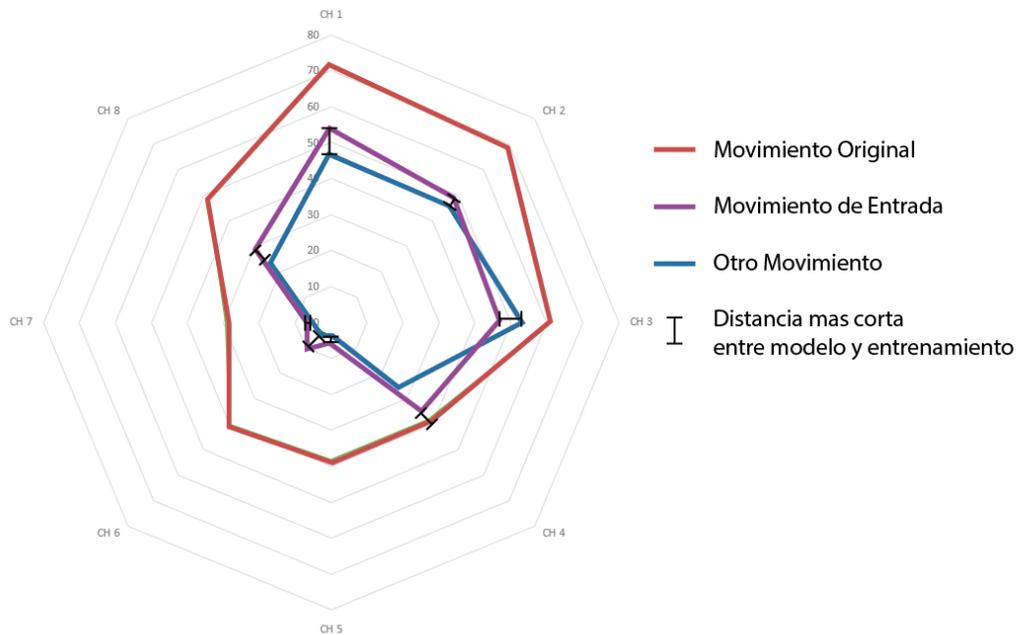


Fig. 4.10. Calculo de distancias entre movimiento original y entrada.

Donde se calcula la diferencia de cada centroide calculado previamente de cada canal de un solo movimiento, contra el movimiento ingresado. Este proceso genera una matriz de distancia cuya finalidad es encontrar el movimiento con el que exista menor diferencia de distancias. Este proceso es iterado por todos los movimientos generando la matriz de distancias entre el movimiento de prueba y todos los demás movimientos.

El diagrama de flujo que ejemplifica el siguiente proceso se visualiza en la siguiente imagen.

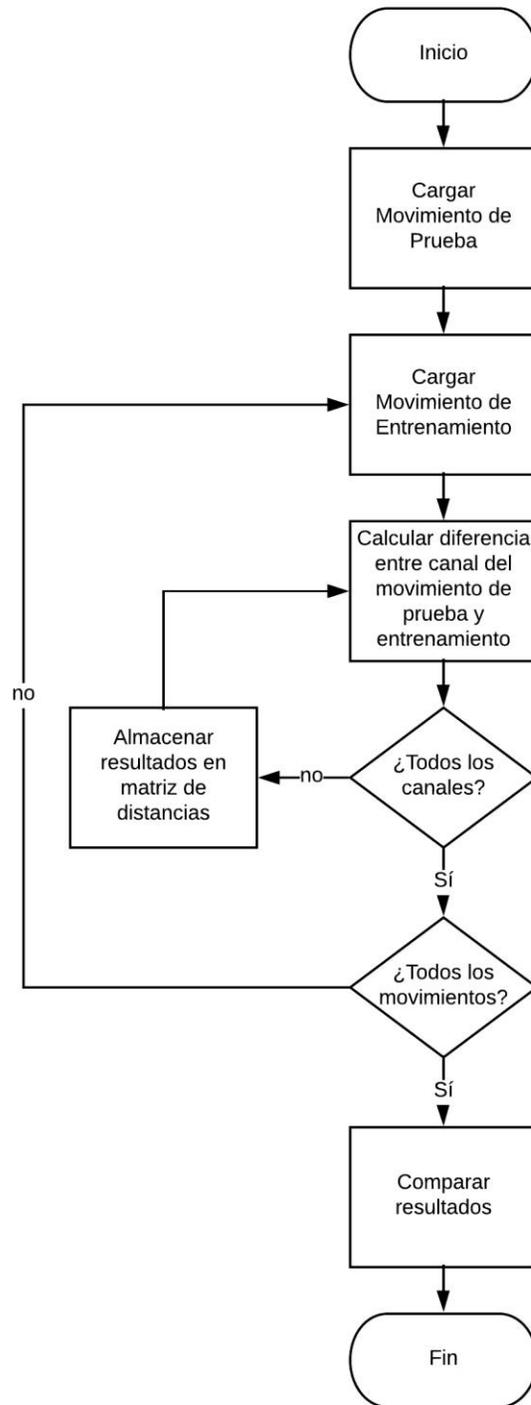


Fig. 4.11. Diagrama de flujo para la clasificación de una señal.

La matriz resultante se suma obteniendo un valor numérico por cada movimiento, se compara que movimiento se aproxima más a nuestro movimiento de prueba, comparando la distancia resultante, el movimiento predicho es aquel con la menor distancia resultante

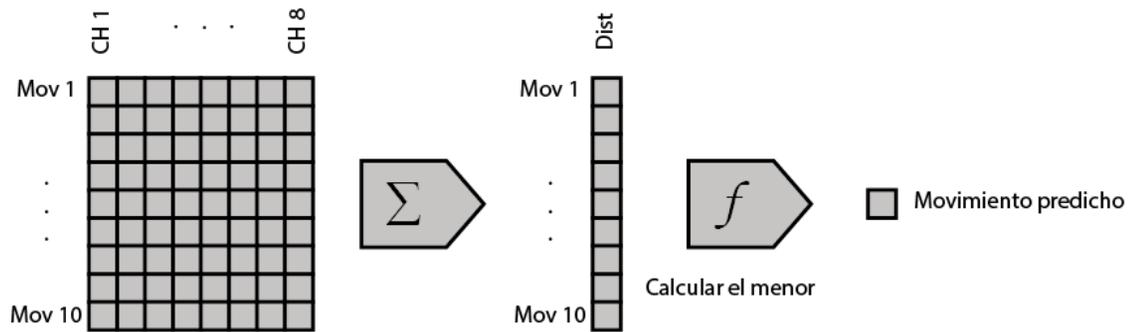


Fig. 4.12. Matriz de distancias de movimientos.

El proceso completo para la clasificación de señales es mostrado en el siguiente diagrama de flujo.

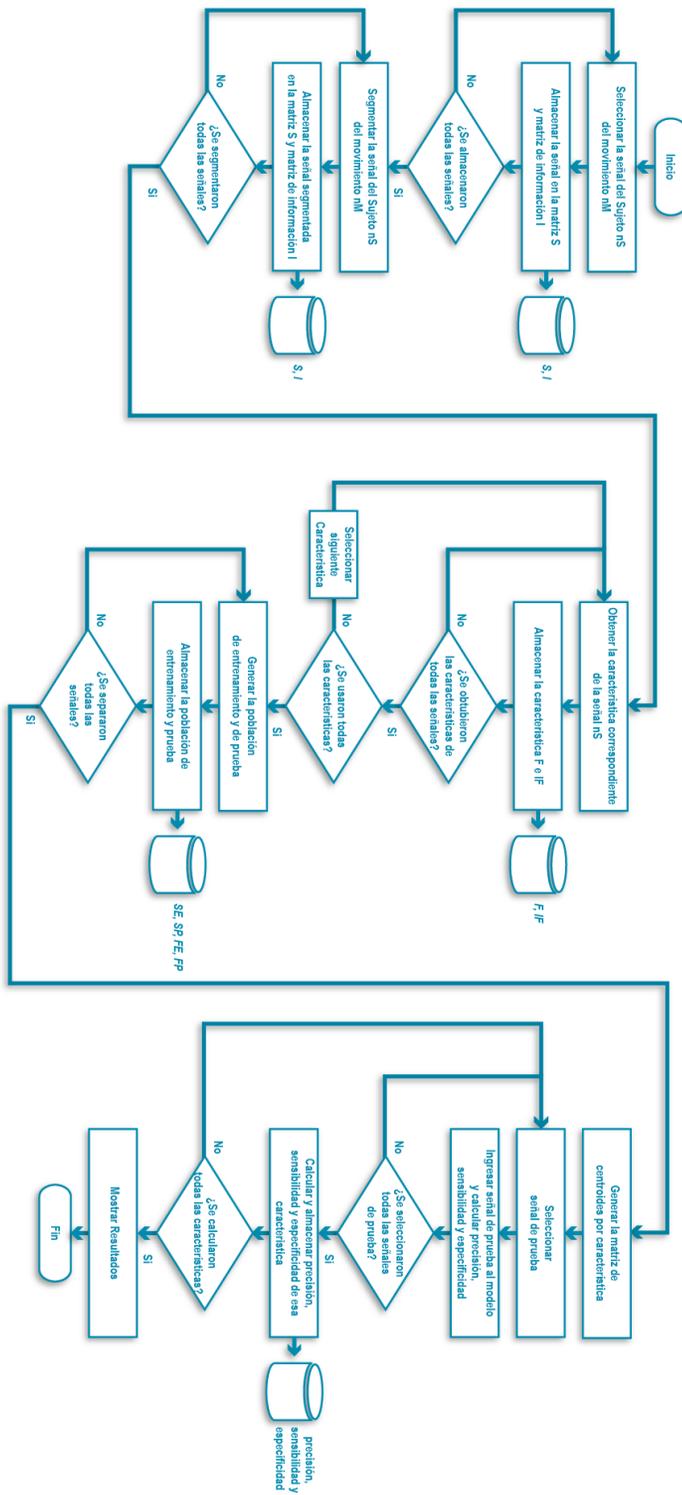


Fig. 4.13. Diagrama de flujo detallando el proceso de clasificación.

4.2 Discusión de Resultados

A continuación, se visualizan las señales adquiridas de un solo participante para todos los movimientos de ambos brazos. En cada movimiento se puede observar algunos canales que son más significativos que otros, pero aún no es suficiente para obtener las características necesarias para poder clasificar el movimiento. En cada una se muestra la señal completa y se pueden observar las cinco repeticiones en una ventana. Como resultado de aplicar un filtro wavelet db4 nivel 10, visualmente las señales se pueden observar más limpias, permitiendo así la extracción de características por cada señal. A partir de este punto se puede observar la diferencia entre movimientos generados por los músculos flexores y extensores a los generados por otros músculos de la muñeca. Los resultados de extracción de características y cálculo de centroides se pueden observar en las siguientes graficas radiales, se graficaron de esta manera para para poder observar la intensidad de la actividad en cada canal por movimiento, en una sola gráfica.

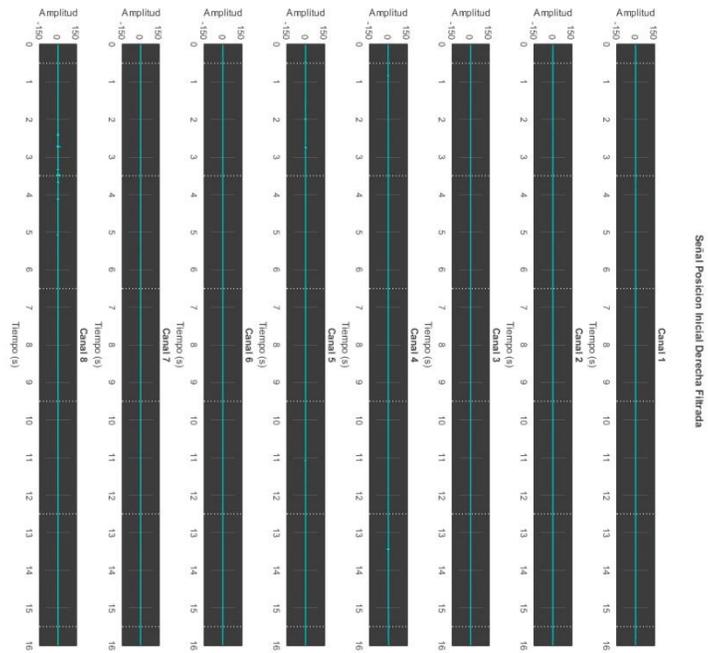
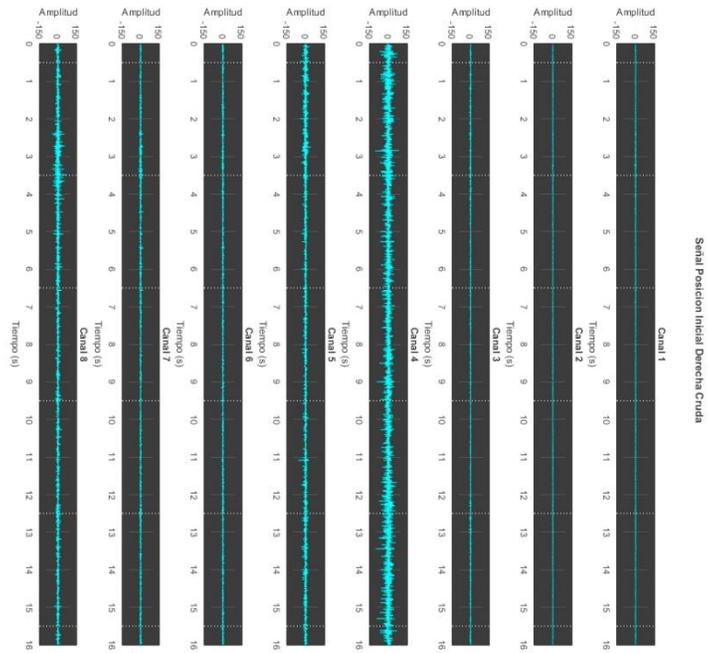


Fig. 4.15. Comparación de señales en bruto y filtradas para el movimiento posición inicial en el brazo derecho.

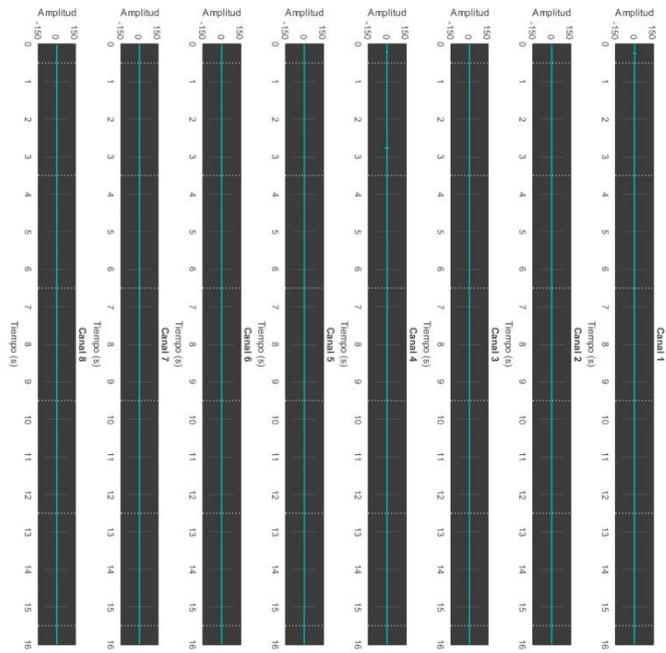
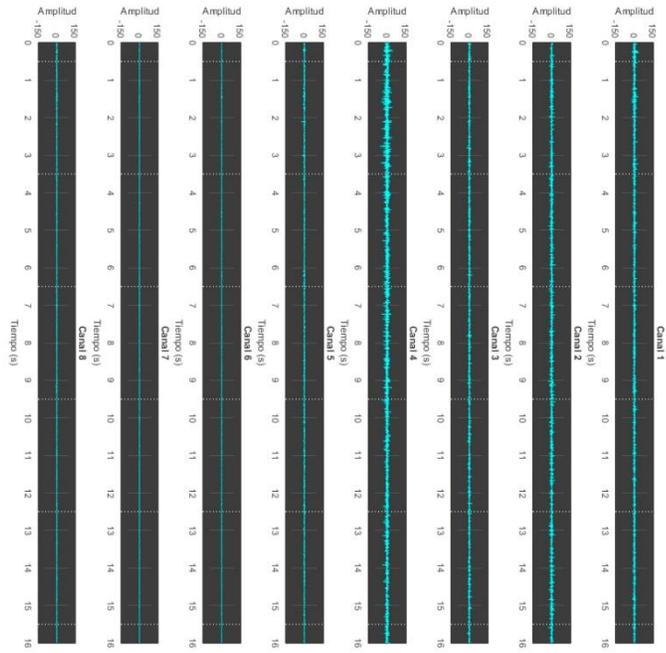


Fig. 4.16. Comparación de señales en bruto y filtradas para el movimiento posición inicial en el brazo izquierdo.

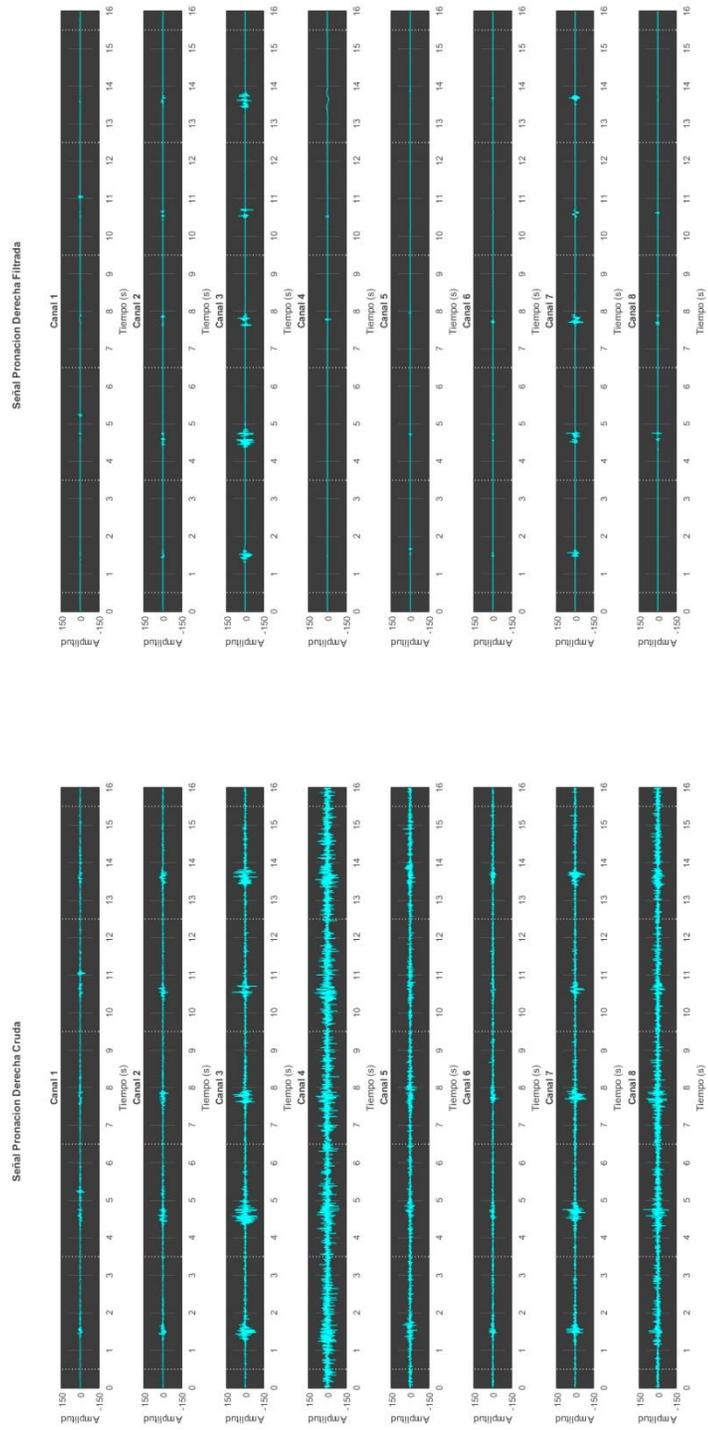
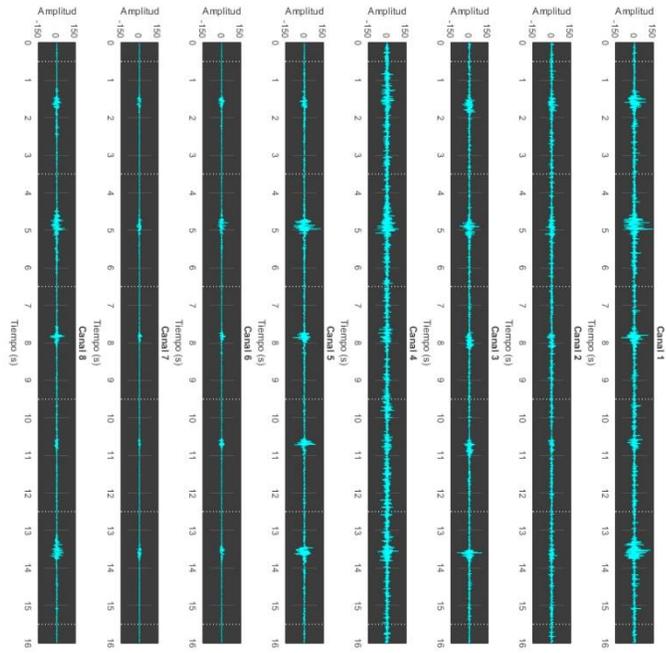
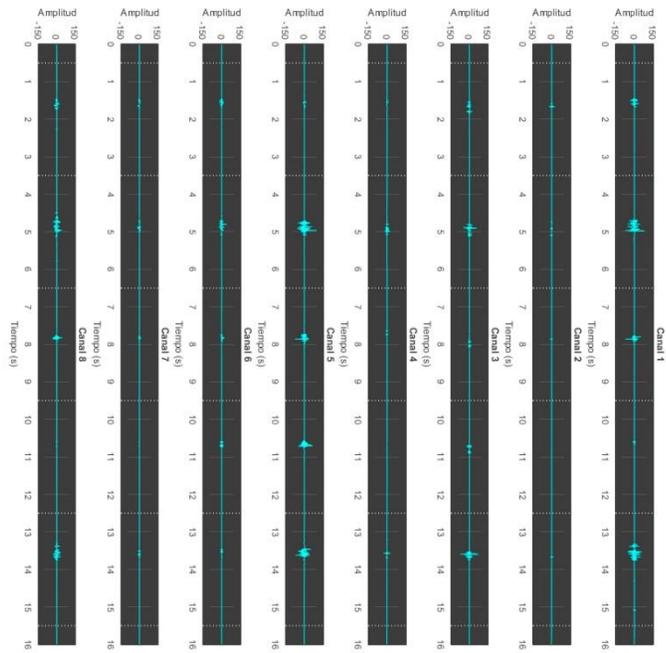


Fig. 4.17. Comparación de señales en bruto y filtradas para el movimiento pronación en el brazo derecho.



Señal Pronación Izquierda Cruda



Señal Pronación Izquierda Filtrada

Fig. 4.18. Comparación de señales en bruto y filtradas para el movimiento pronación en el brazo izquierdo.

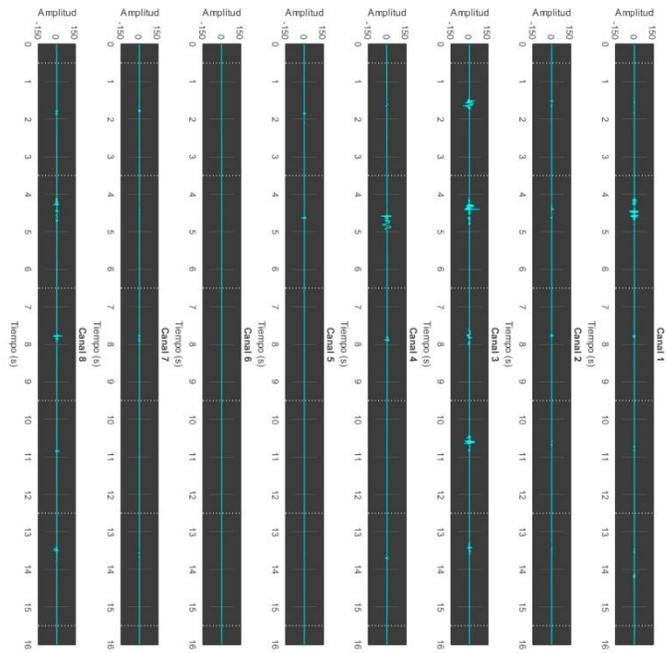
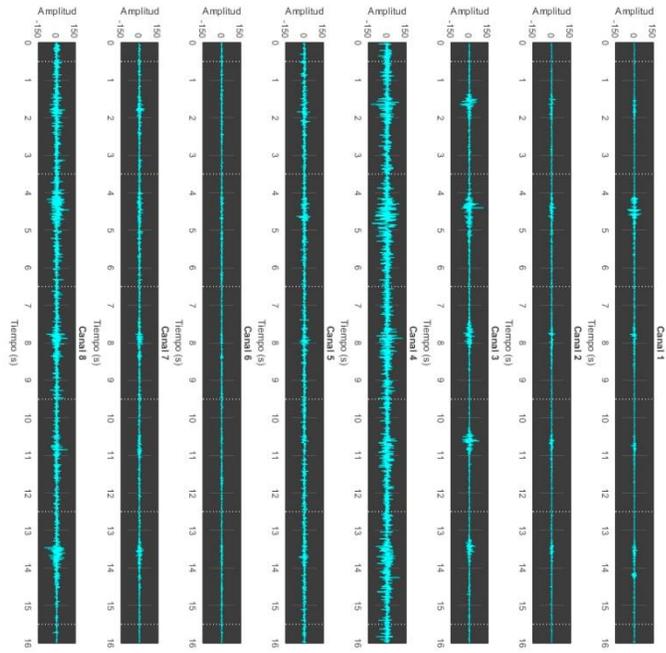


Fig. 4.19. Comparación de señales en bruto y filtradas para el movimiento supinación en el brazo derecho.

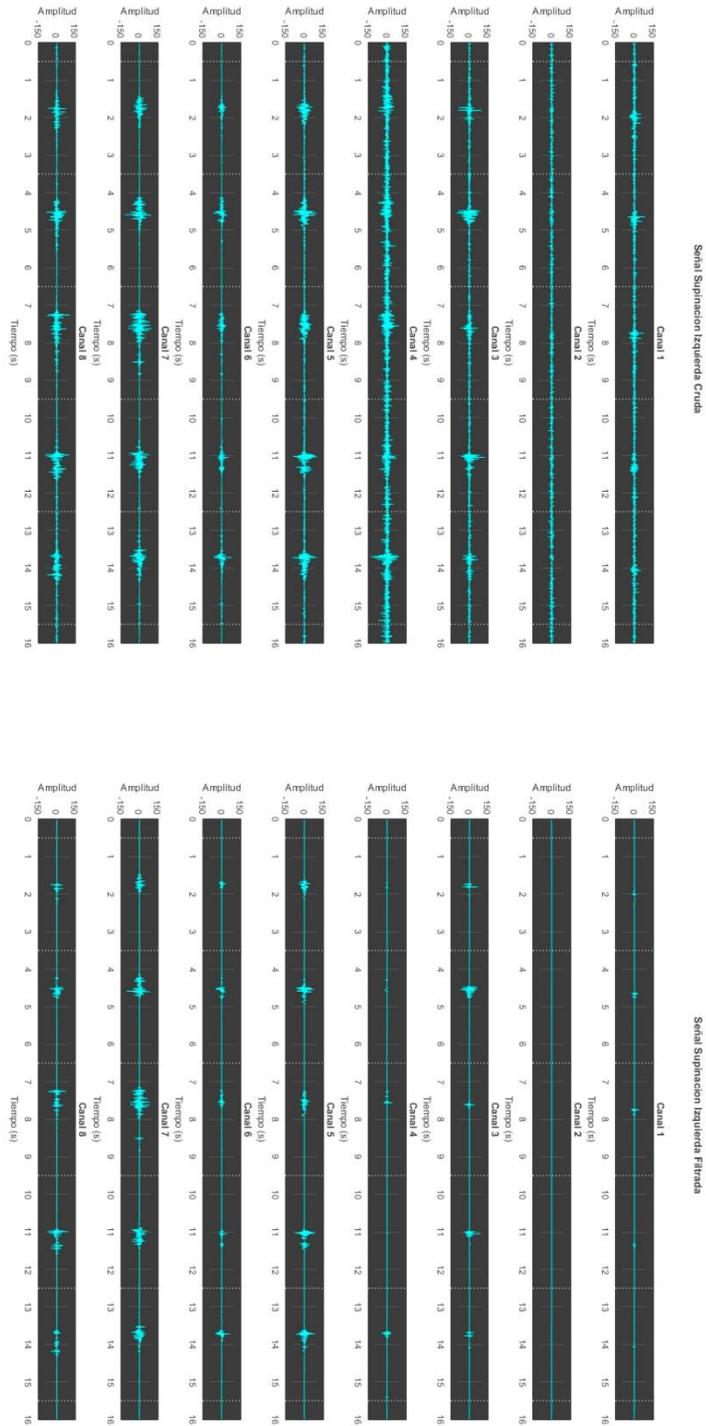
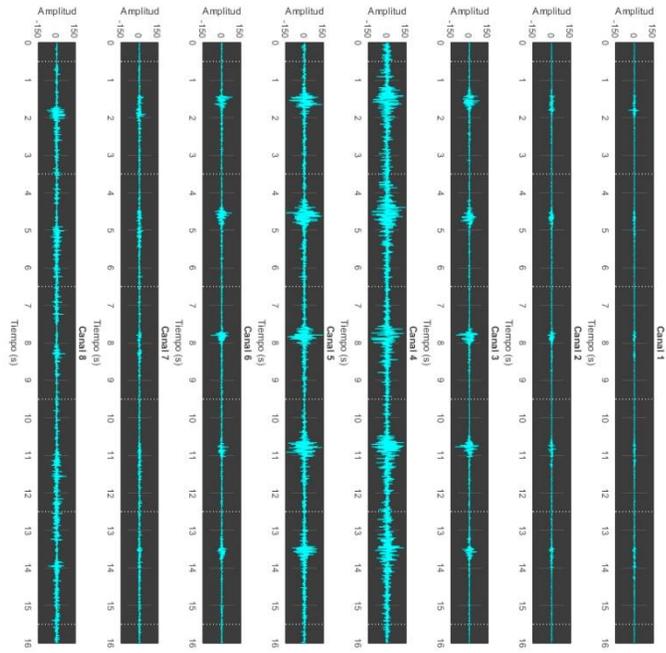
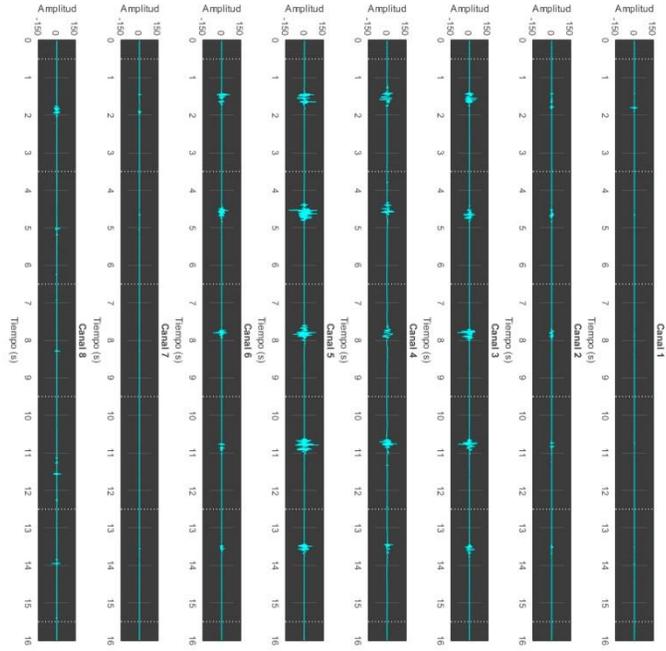


Fig. 4.20. Comparación de señales en bruto y filtradas para el movimiento supinación en el brazo izquierdo.



Señal Extensión Derecha Cruda



Señal Extensión Derecha Filtrada

Fig. 4.21. Comparación de señales en bruto y filtradas para el movimiento extensión en el brazo derecho

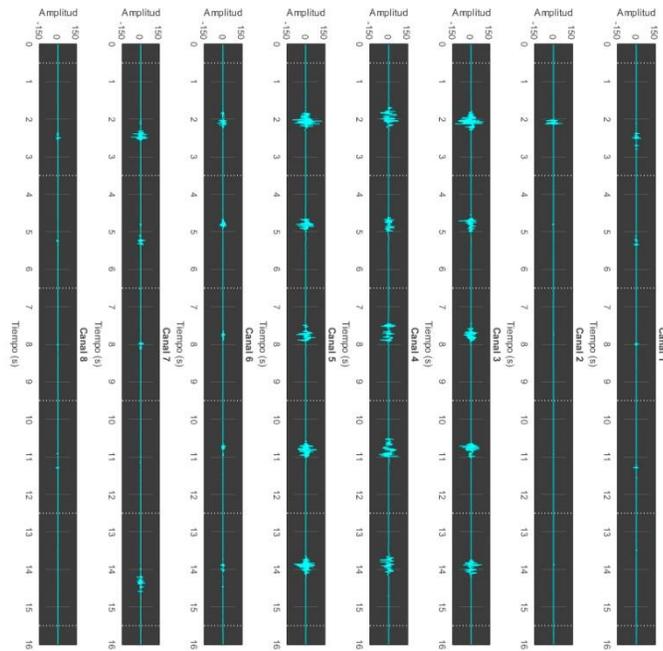
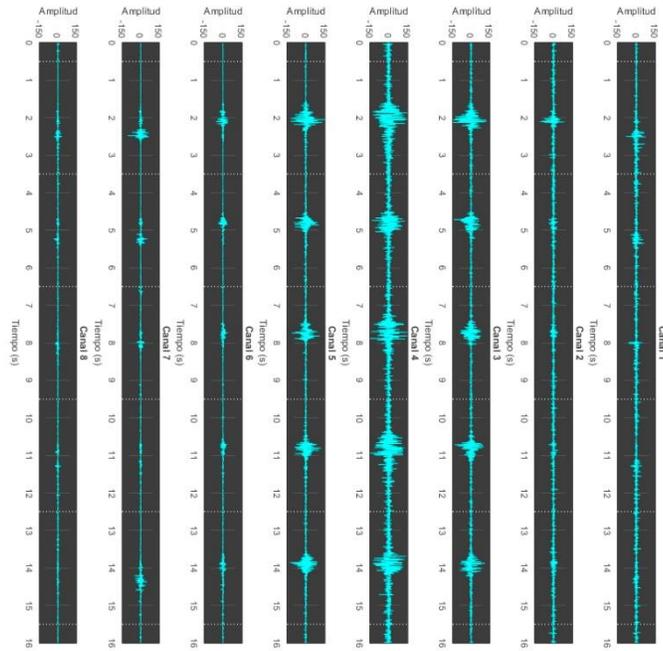


Fig. 4.22. Comparación de señales en bruto y filtradas para el movimiento extensión en el brazo izquierdo.

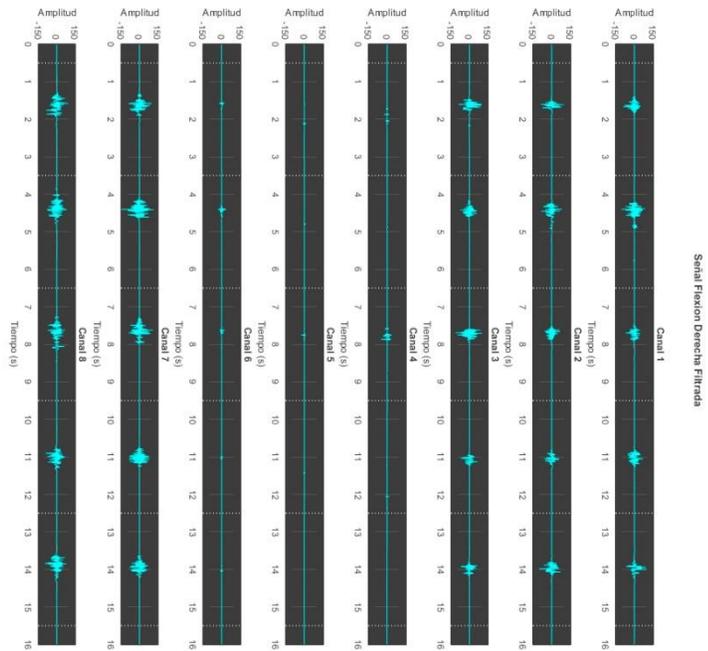
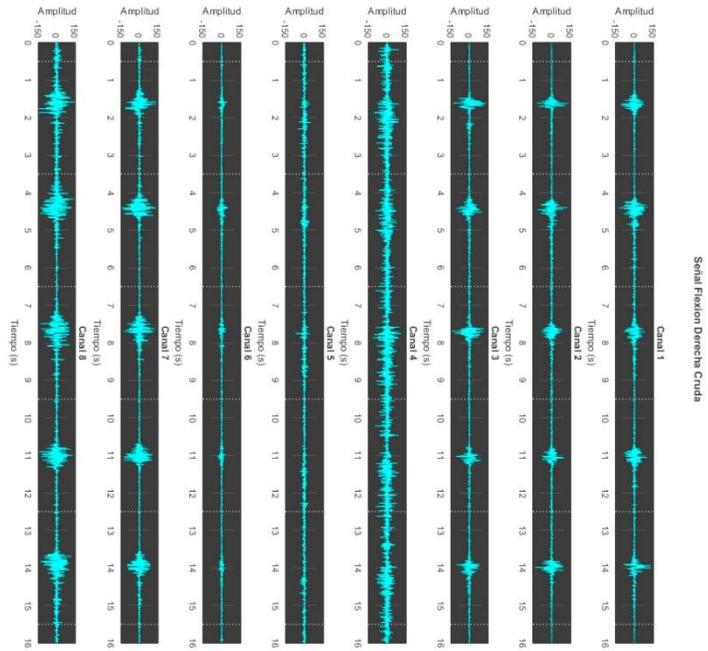


Fig. 4.23. Comparación de señales en bruto y filtradas para el movimiento flexión en el brazo derecho.

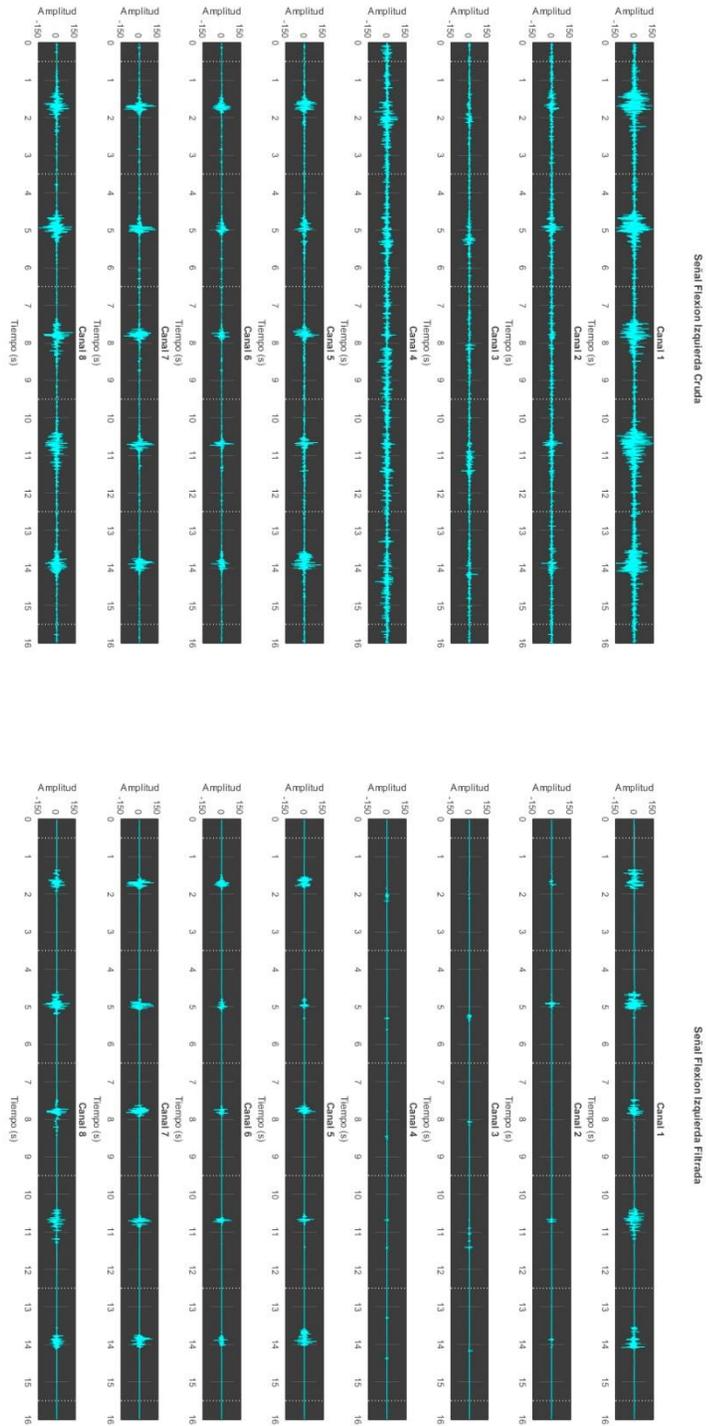


Fig. 4.24. Comparación de señales en bruto y filtradas para el movimiento flexión en el brazo izquierdo.

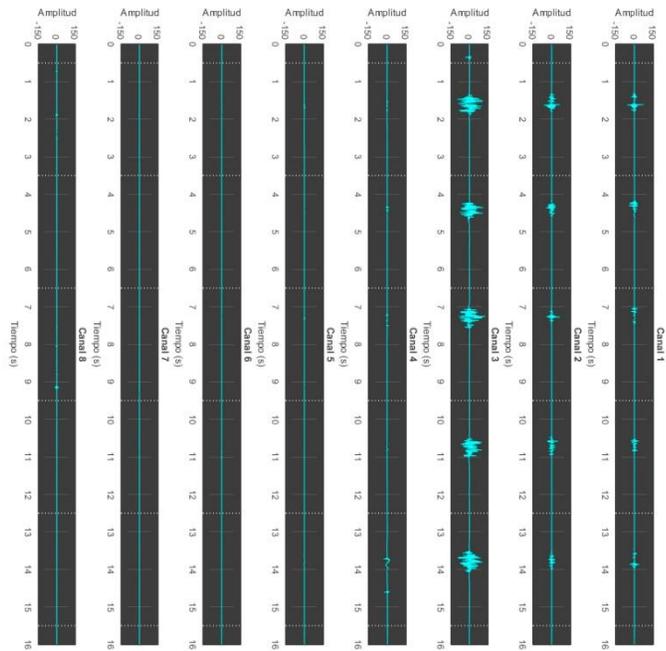
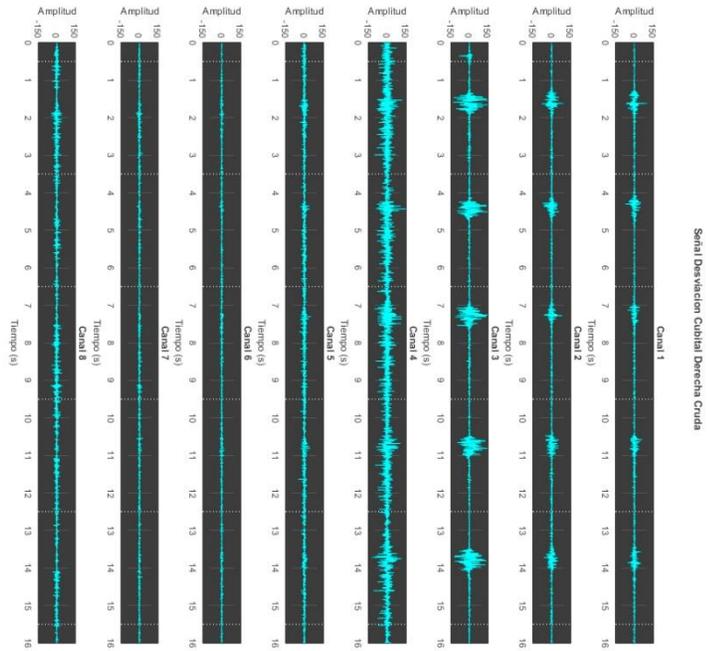


Fig. 4.25. Comparación de señales en bruto y filtradas para el movimiento desviación cubital en el brazo derecho

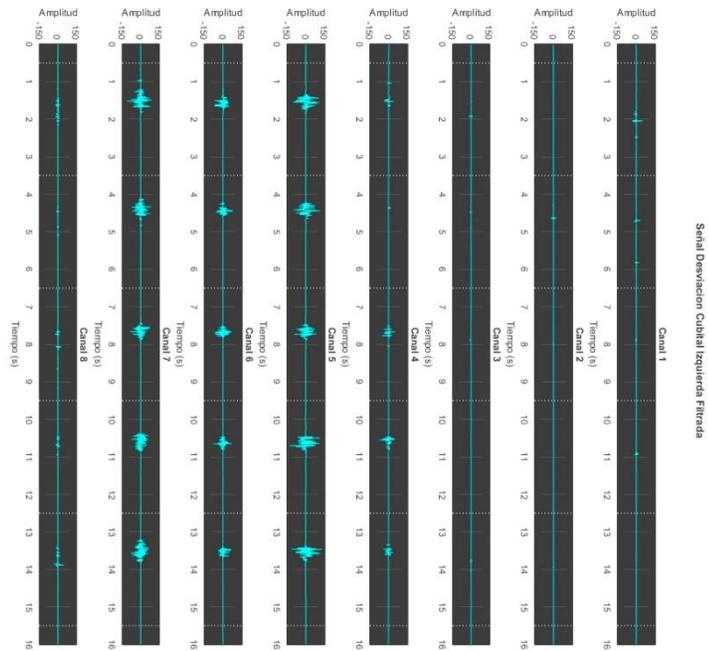
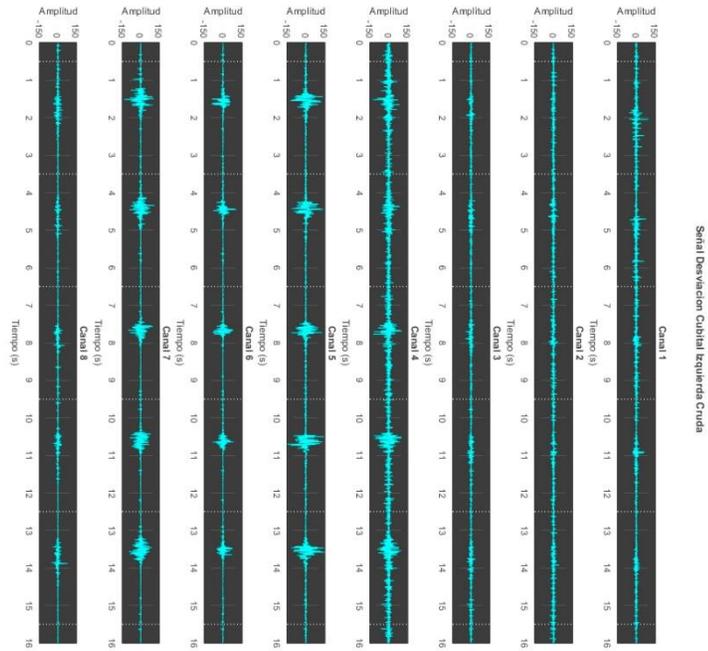


Fig. 4.26. Comparación de señales en bruto y filtradas para el movimiento desviación cubital en el brazo izquierdo.

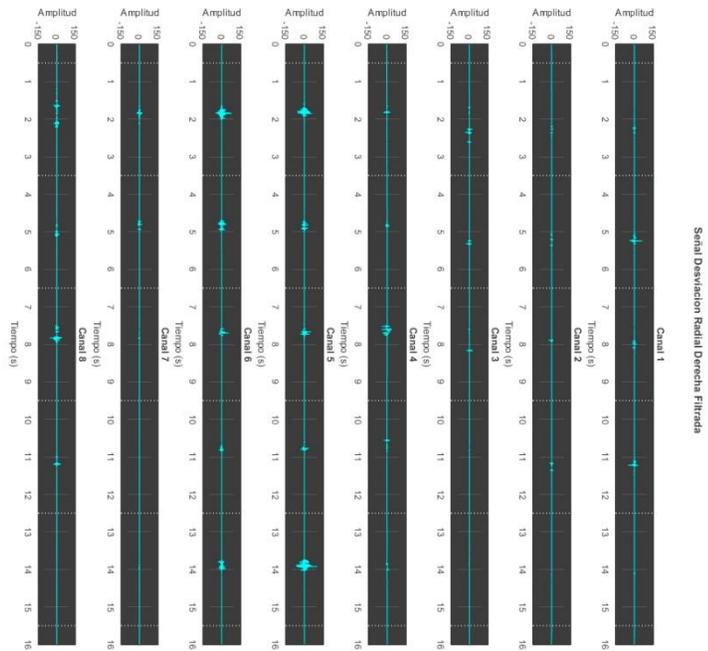
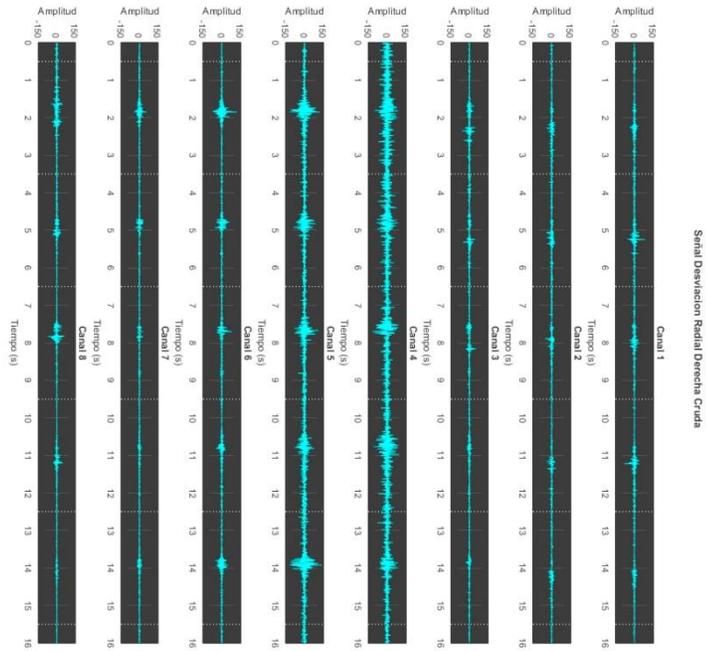


Fig. 4.27. Comparación de señales en bruto y filtradas para el movimiento desviación radial en el brazo derecho.

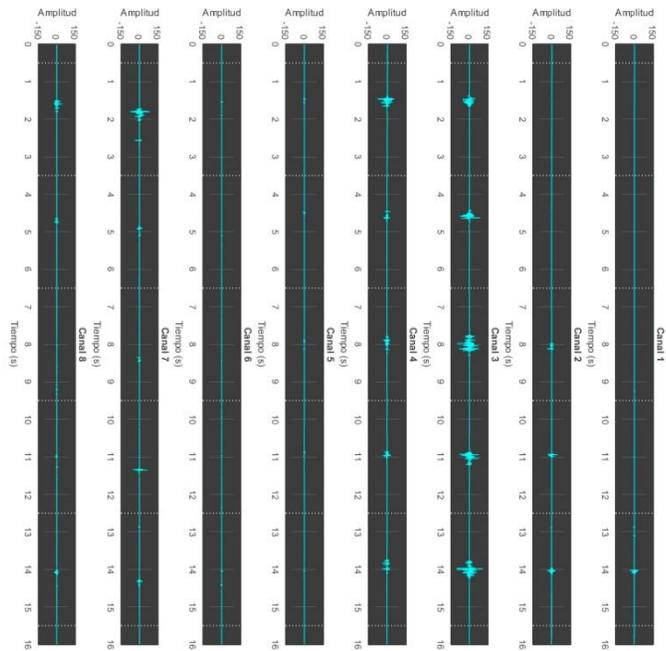
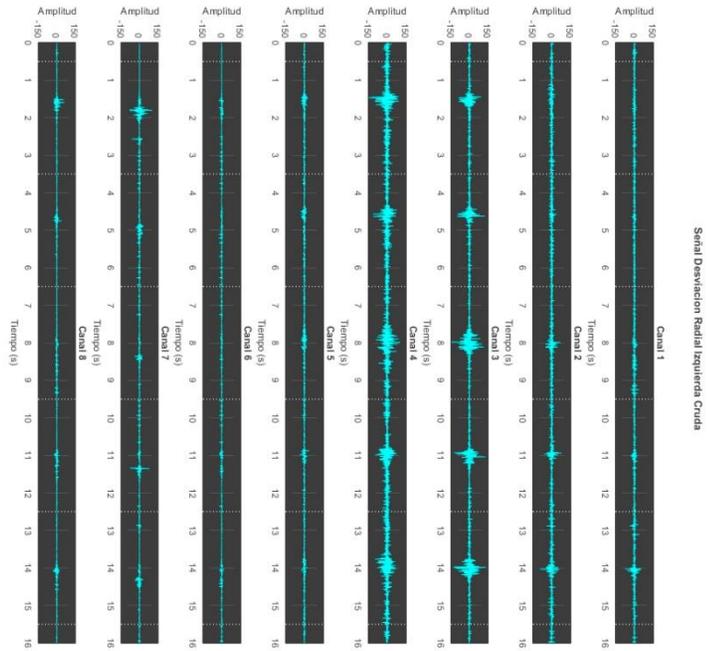
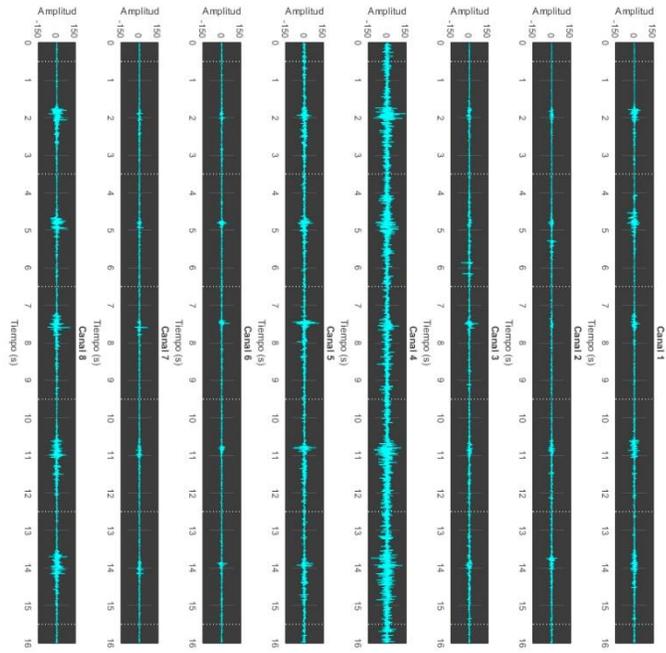
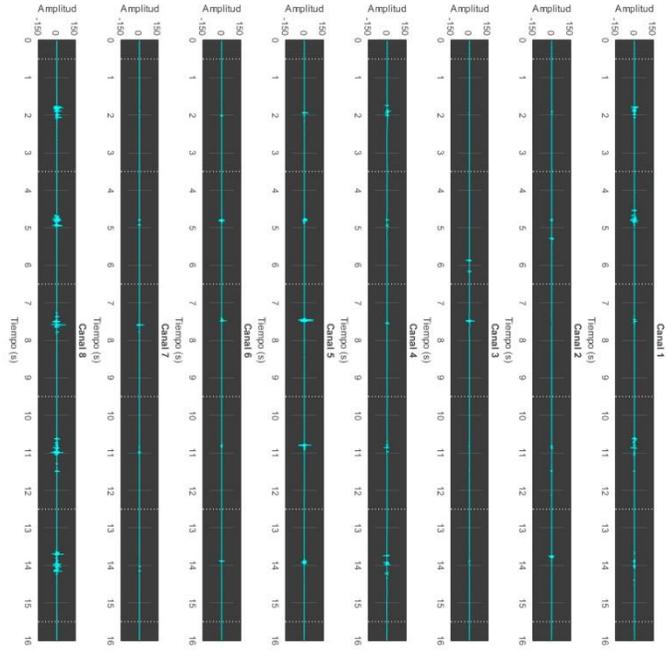


Fig. 4.28. Comparación de señales en bruto y filtradas para el movimiento desviación radial en el brazo izquierdo.



Señal Pinza Fina Derecha Cruda



Señal Pinza Fina Derecha Filtrada

Fig. 4.29. Comparación de señales en bruto y filtradas para el movimiento pinza fina en el brazo derecho

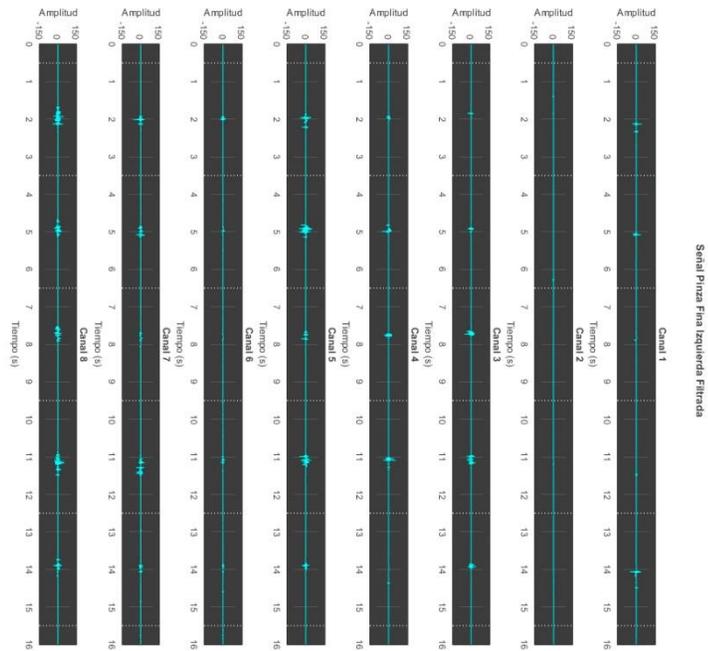
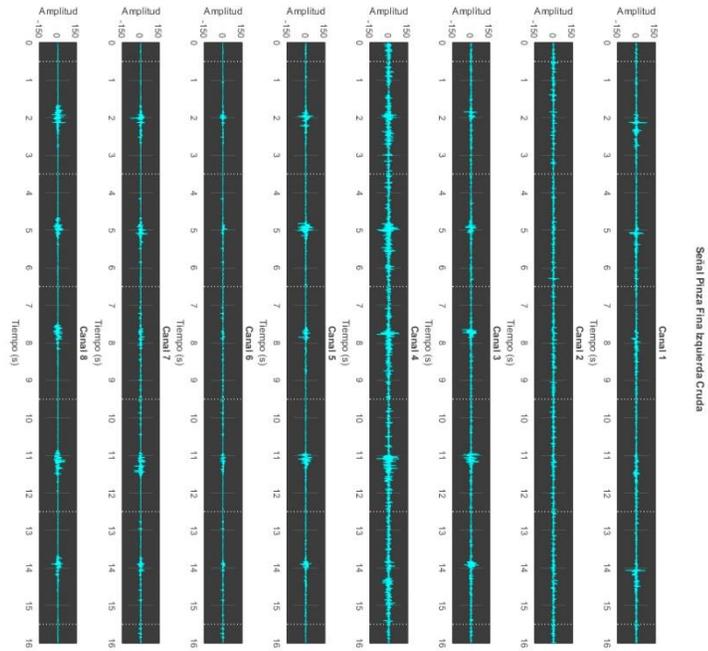
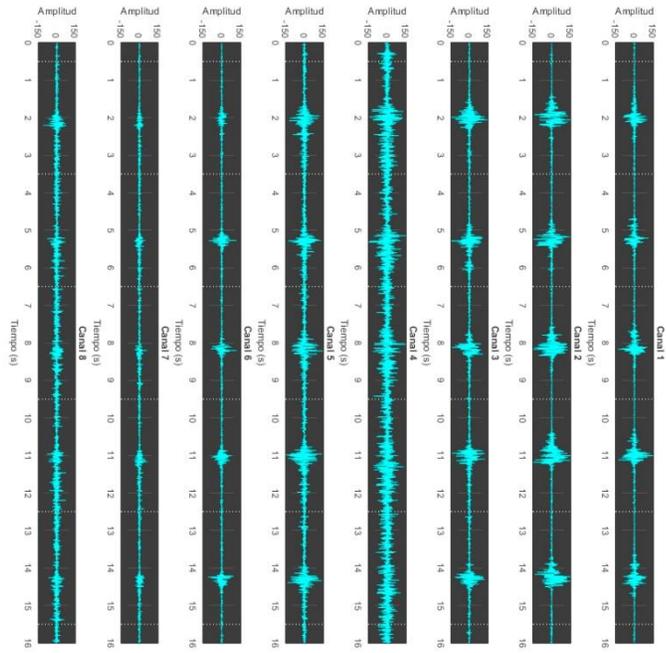
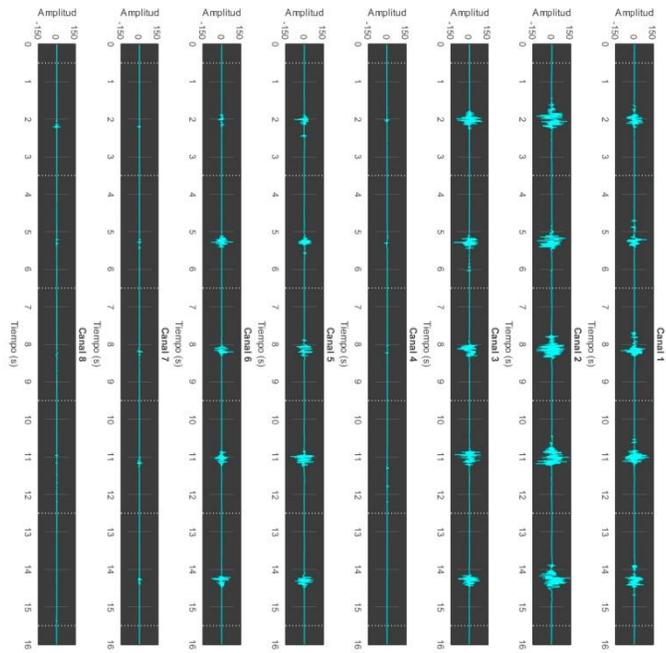


Fig. 4.30. Comparación de señales en bruto y filtradas para el movimiento pinza fina en el brazo izquierdo.

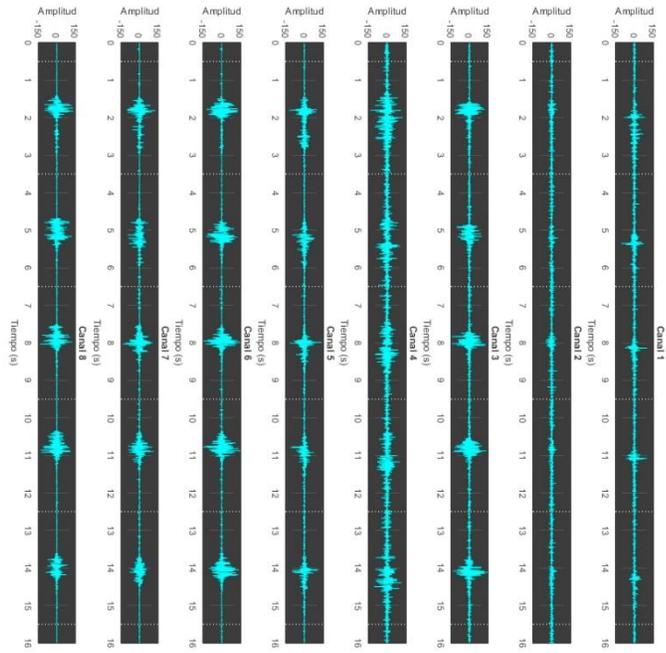


Señal Pinza Gruesa Derecha Cruda

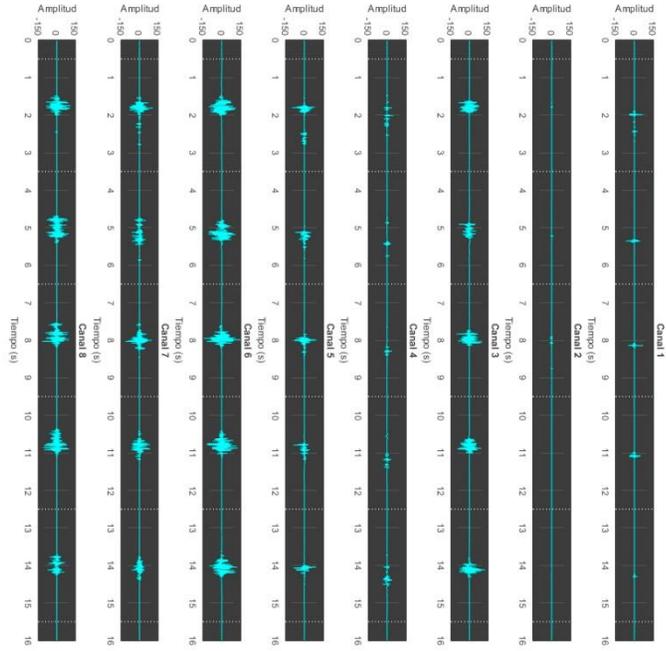


Señal Pinza Gruesa Derecha Filtrada

Fig. 4.31. Comparación de señales en bruto y filtradas para el movimiento pinza gruesa en el brazo derecho.



Señal Pinza Gruesa Izquierda Cruda



Señal Pinza Gruesa Izquierda Filtrada

Fig. 4.32. Comparación de señales en bruto y filtradas para el movimiento pinza gruesa en el brazo izquierdo.

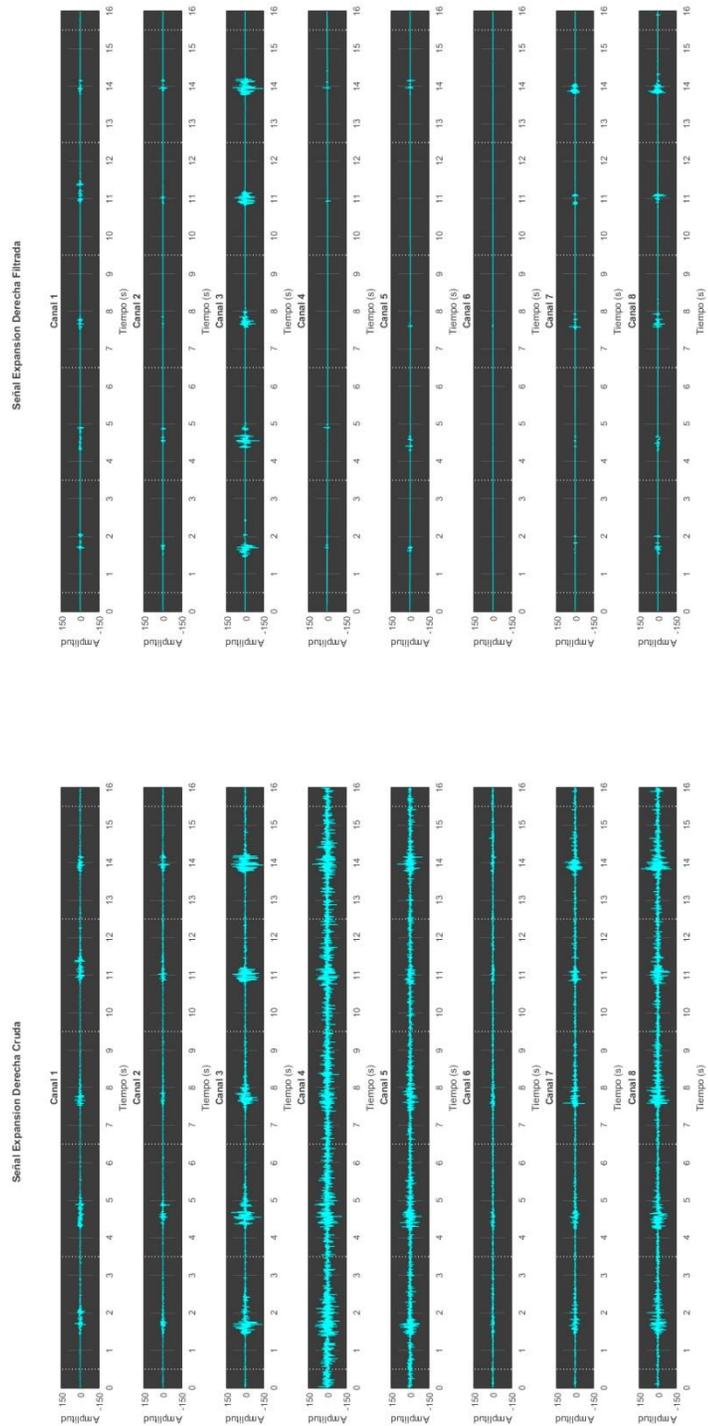


Fig. 4.33. Comparación de señales en bruto y filtradas para el movimiento expansión en el brazo derecho.

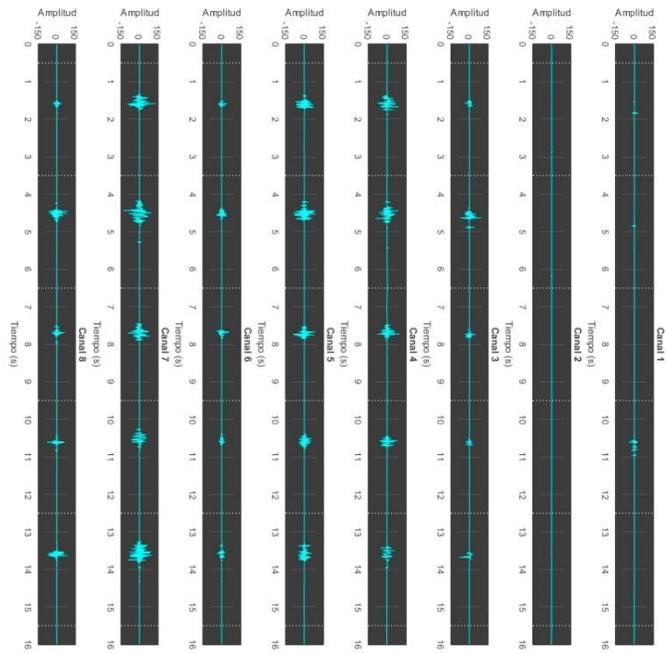
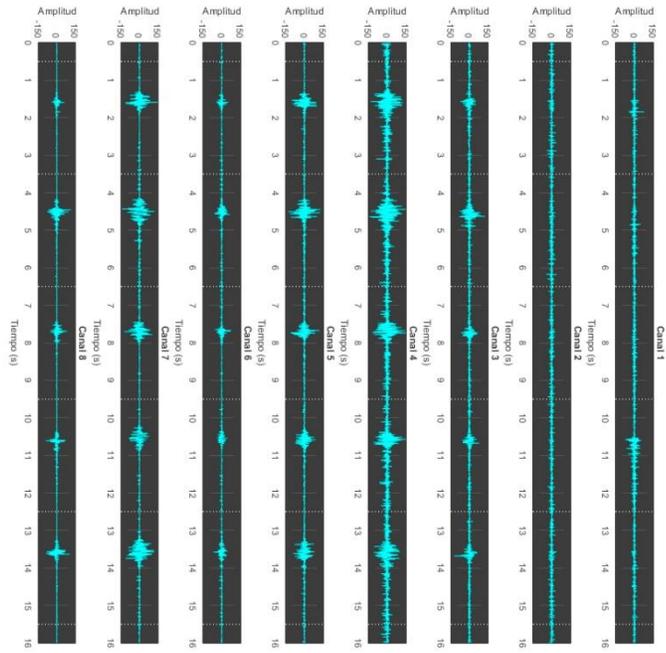


Fig. 4.34. Comparación de señales en bruto y filtradas para el movimiento expansión en el brazo izquierdo.

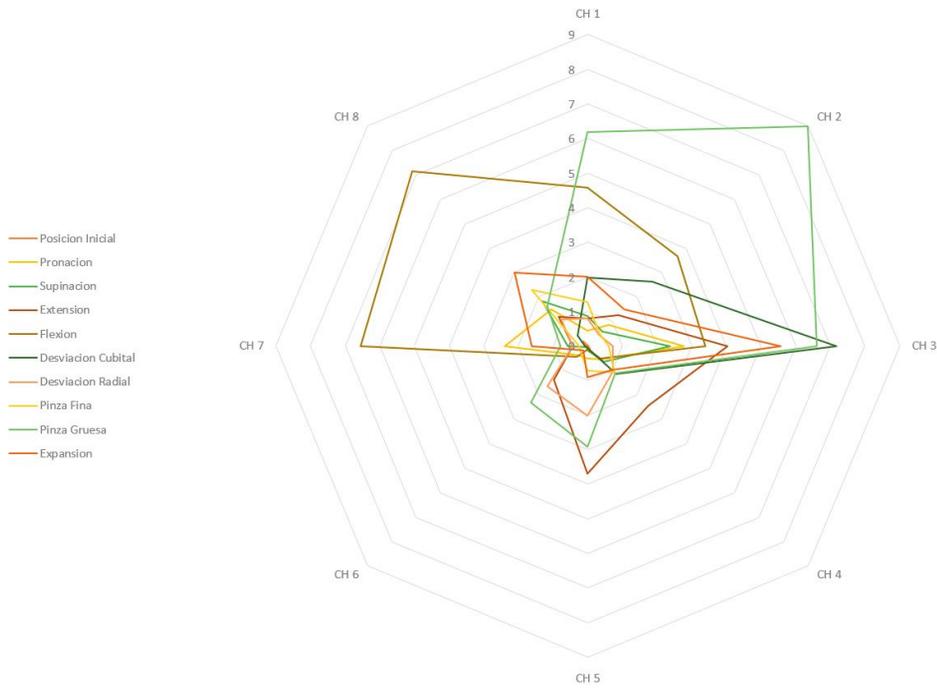


Fig. 4.35 (a). Gráfica Radial de Centroides de la característica AAC para el brazo derecho

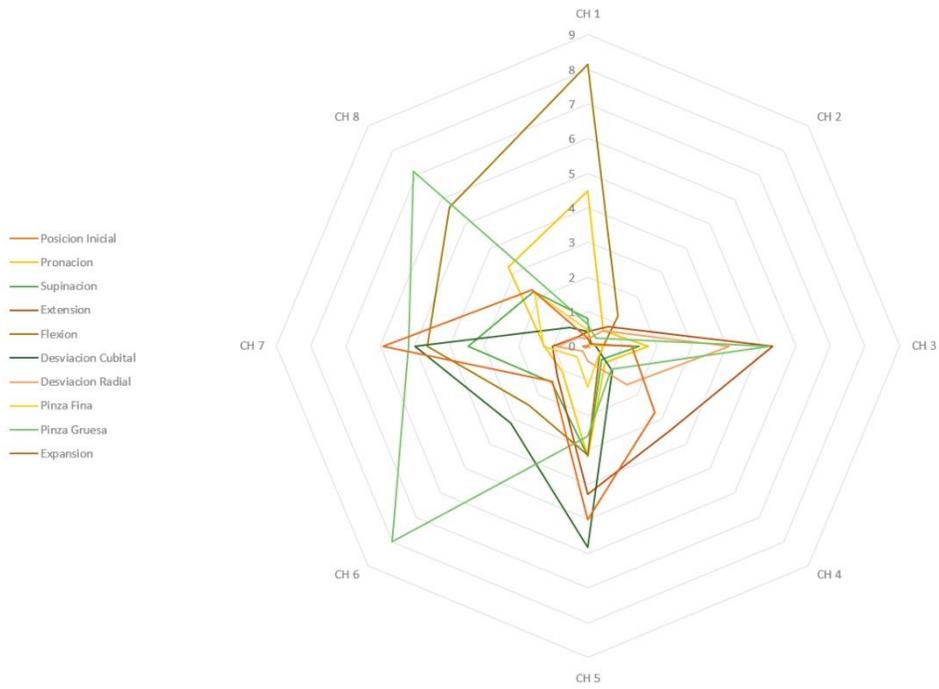


Fig. 4. 35 (b). Gráfica Radial de Centroides de la característica AAC para el brazo izquierdo

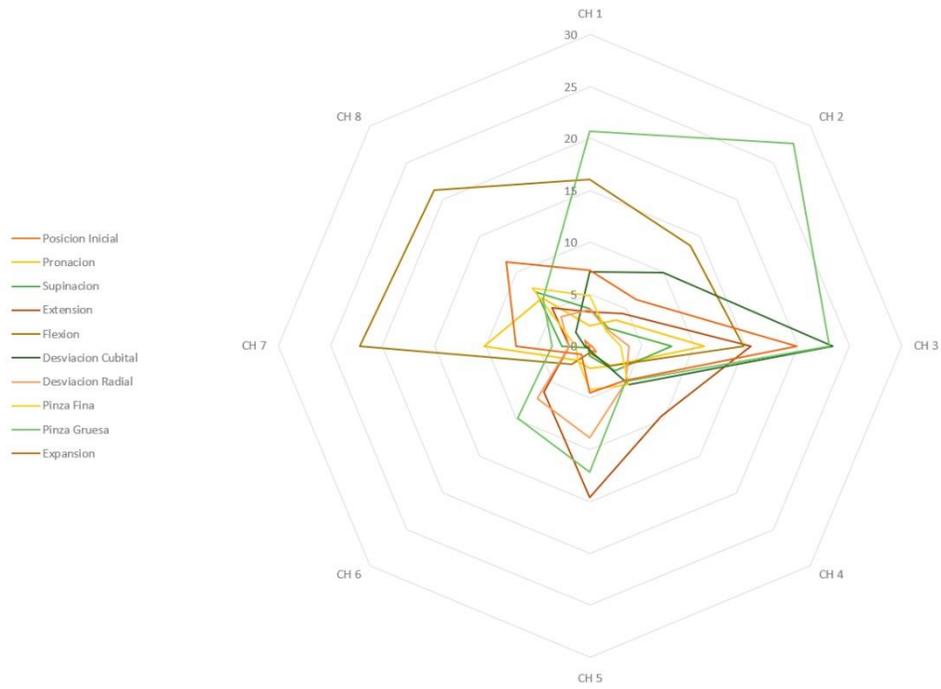


Fig. 4.36 (a). Gráfica Radial de Centroides de la característica DASDV para el brazo derecho

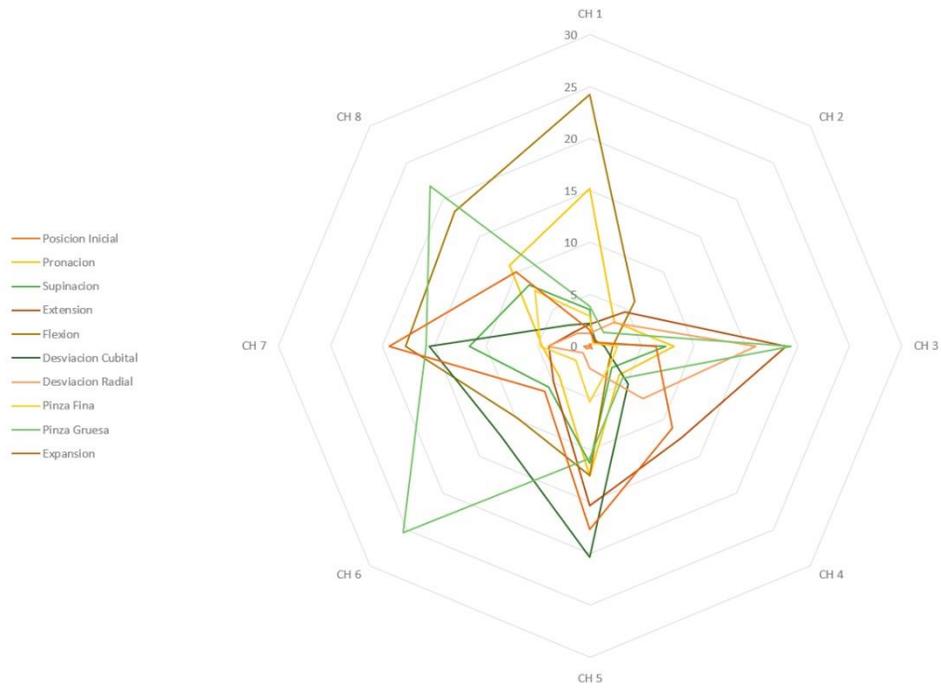


Fig. 4.36 (b). Gráfica Radial de Centroides de la característica DASDV para el brazo izquierdo

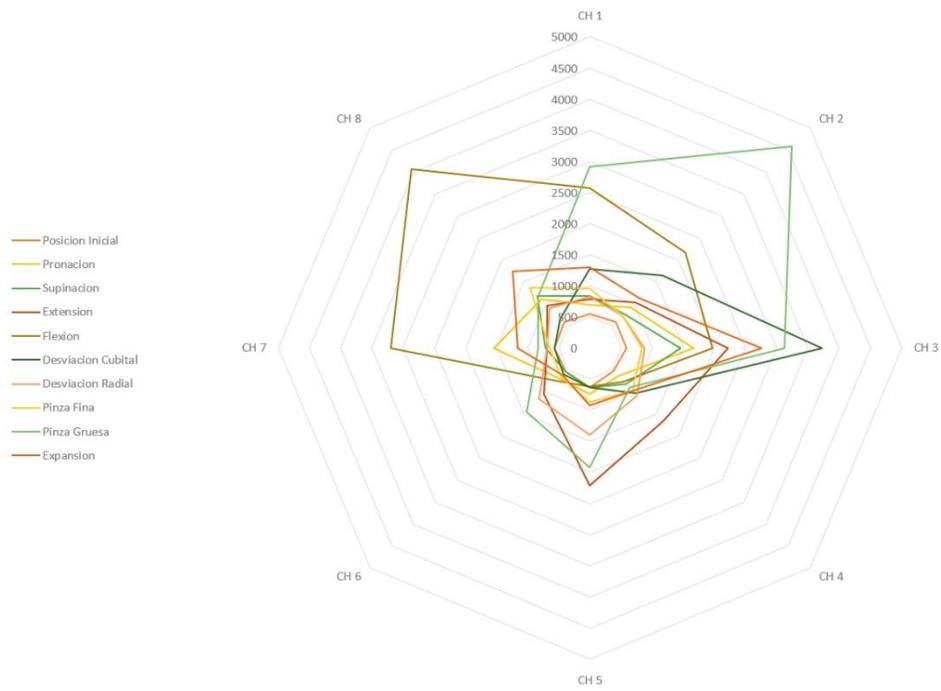


Fig. 4.37 (a). Gráfica Radial de Centroides de la característica IEMG para el brazo derecho

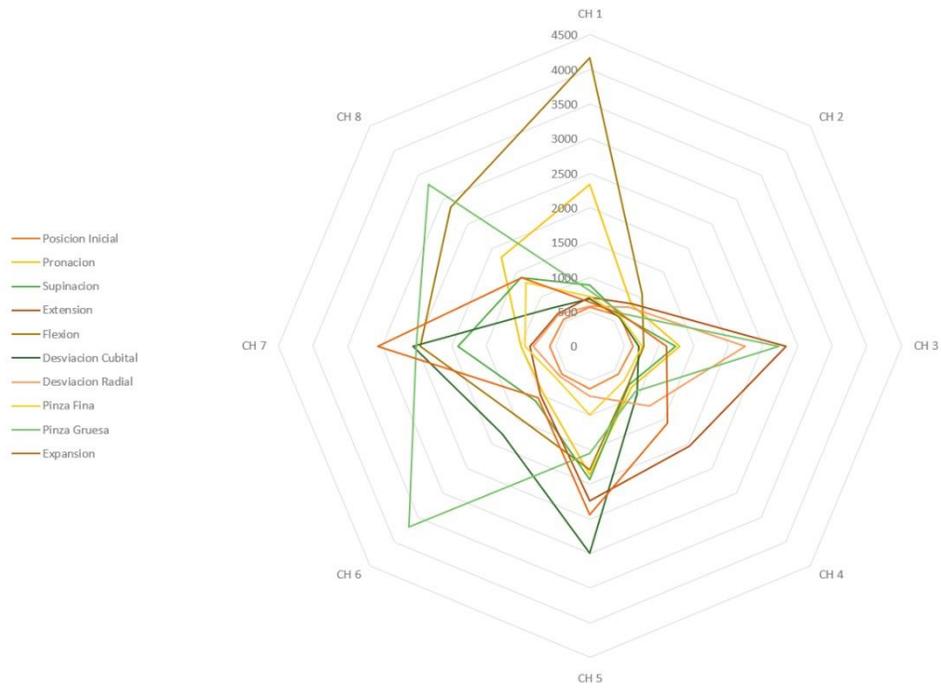


Fig. 4.37 (b). Gráfica Radial de Centroides de la característica IEMG para el brazo izquierdo

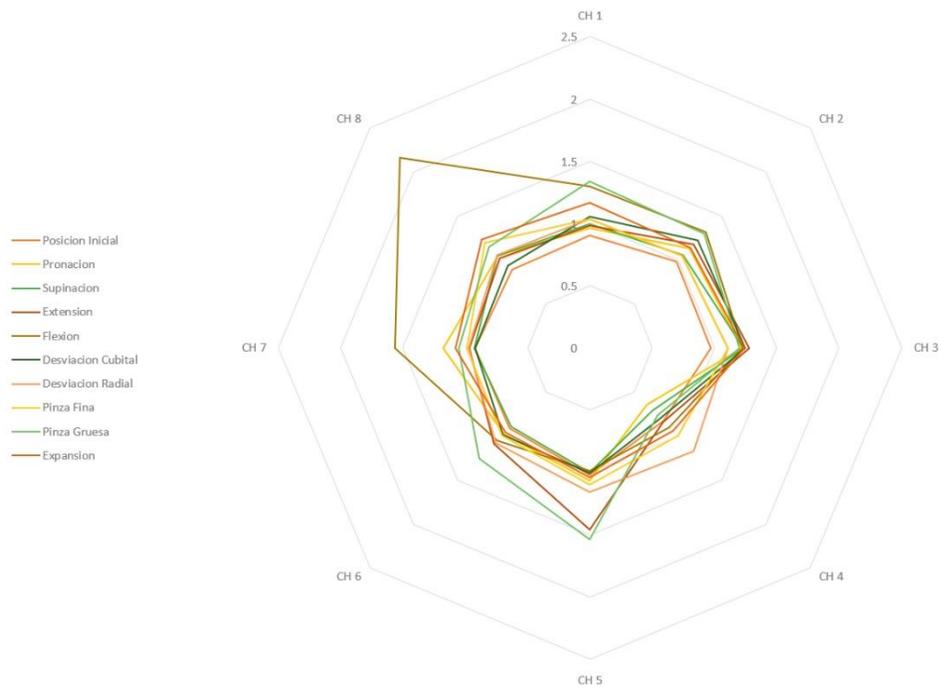


Fig. 4.38 (a). Gráfica Radial de Centroides de la característica LD para el brazo derecho

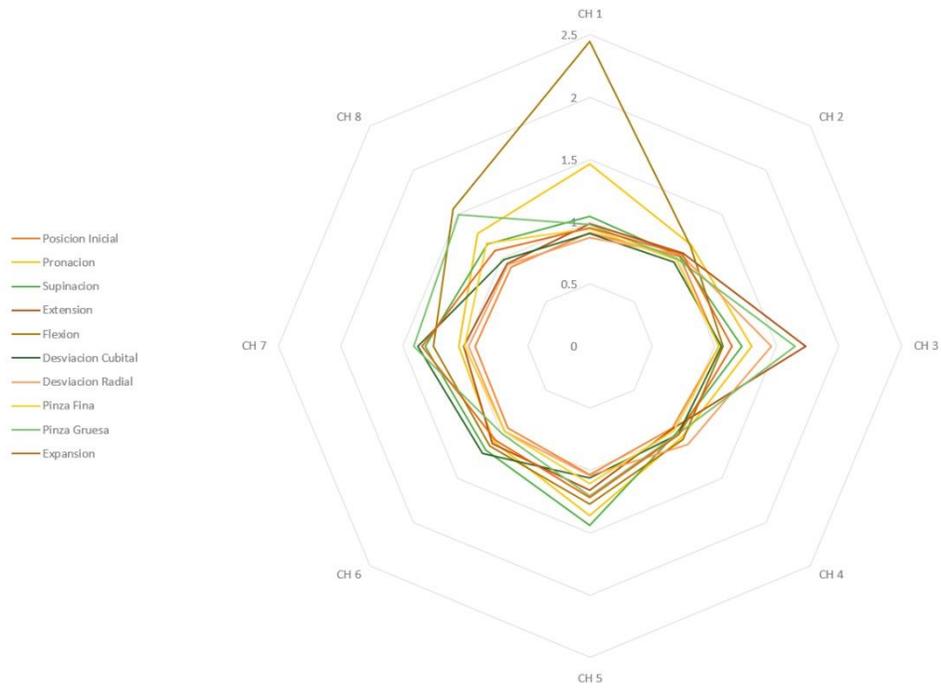


Fig. 4.38 (b). Gráfica Radial de Centroides de la característica LD para el brazo izquierdo

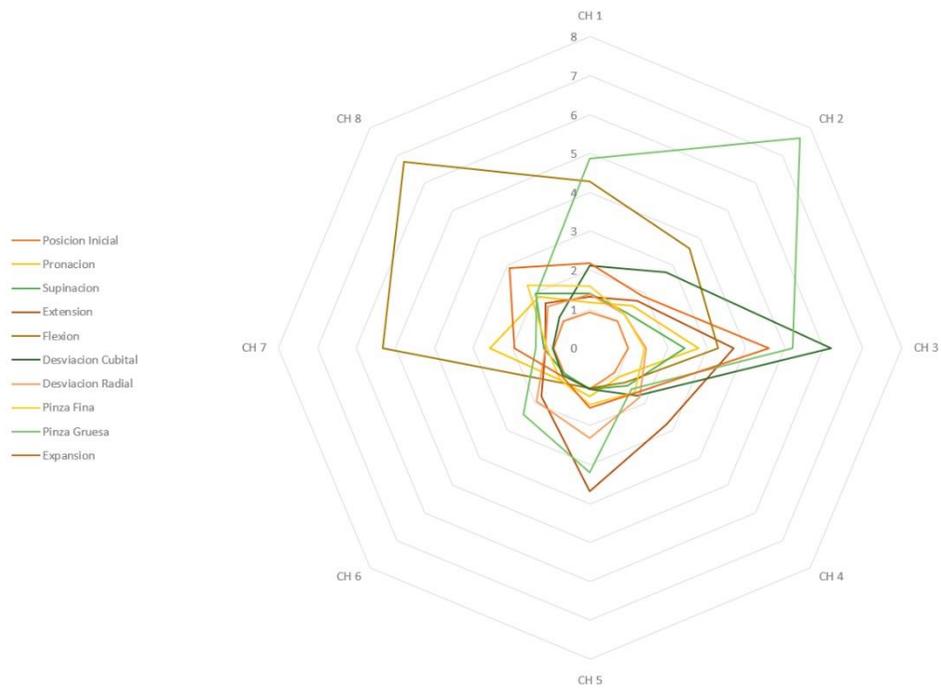


Fig. 4.39 (a). Gráfica Radial de Centroides de la característica MAV para el brazo derecho

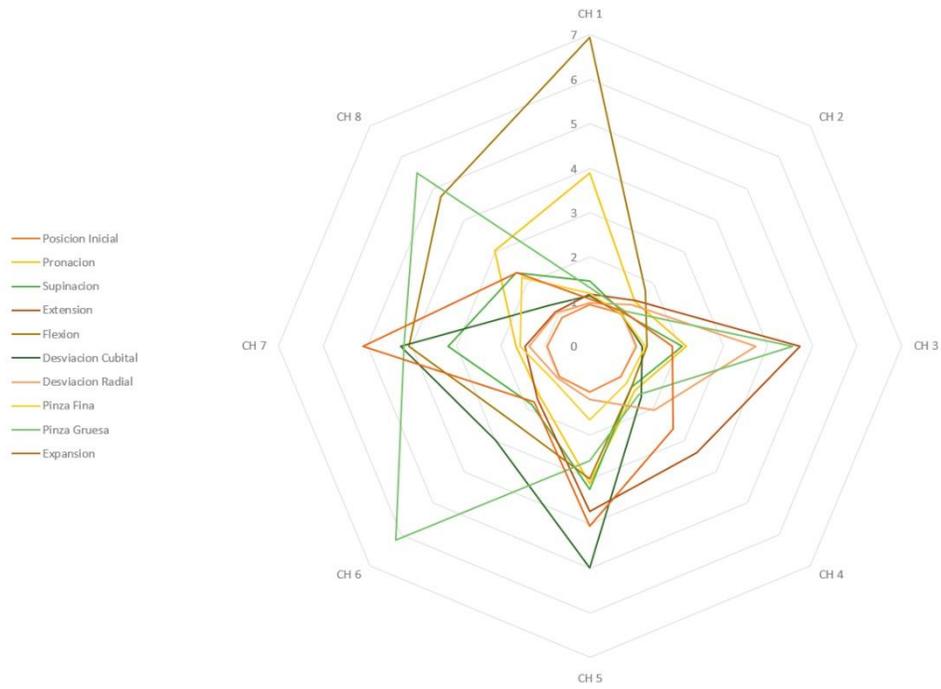


Fig. 4.39 (b). Gráfica Radial de Centroides de la característica MAV para el brazo izquierdo

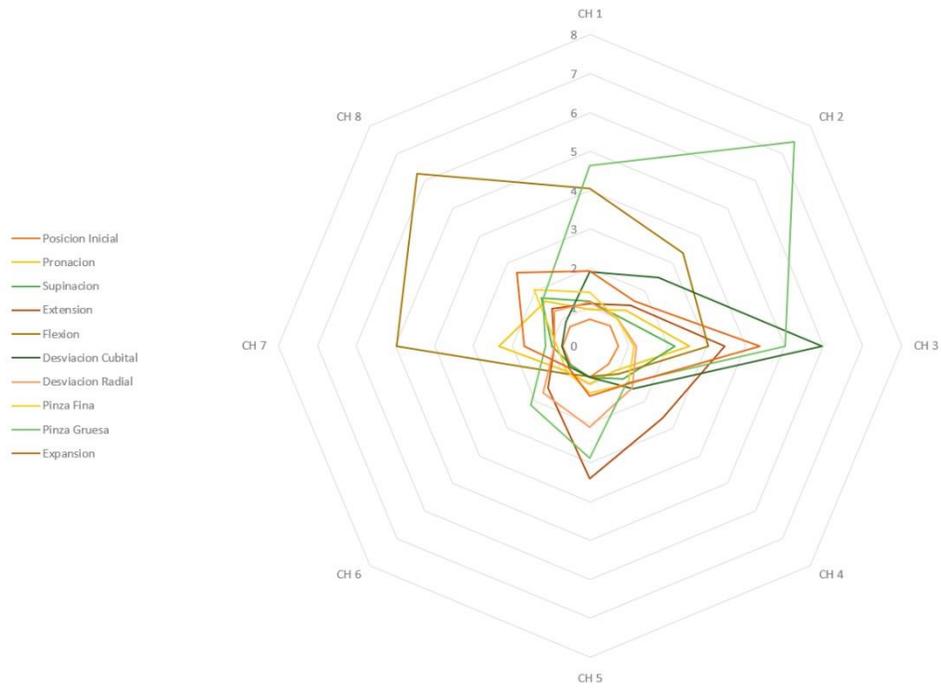


Fig. 4.40 (a). Gráfica Radial de Centroides de la característica MAV1 para el brazo derecho

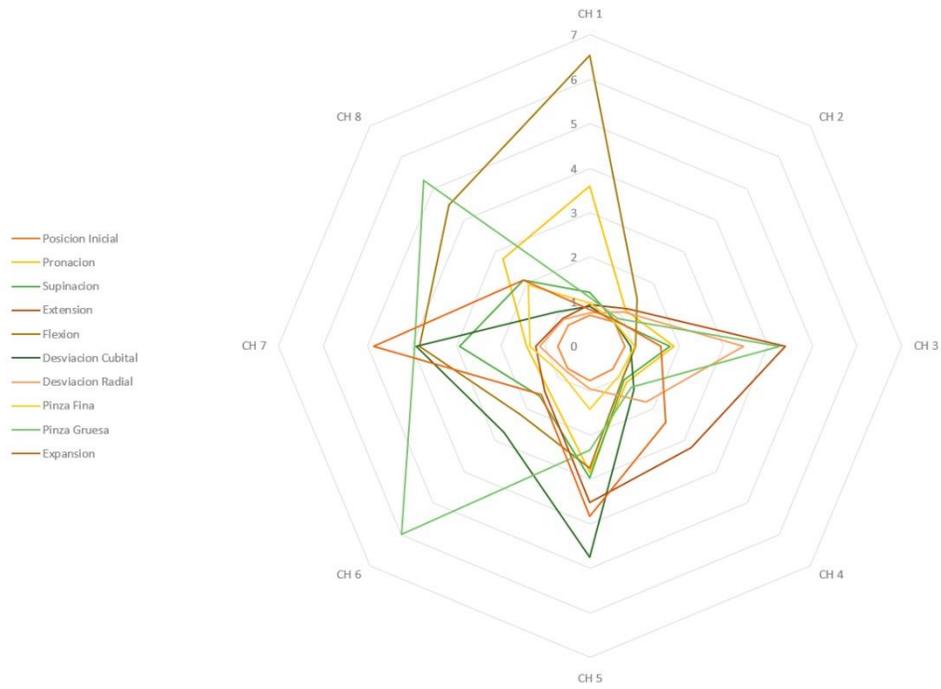


Fig. 4.40 (b). Gráfica Radial de Centroides de la característica MAV1 para el brazo izquierdo

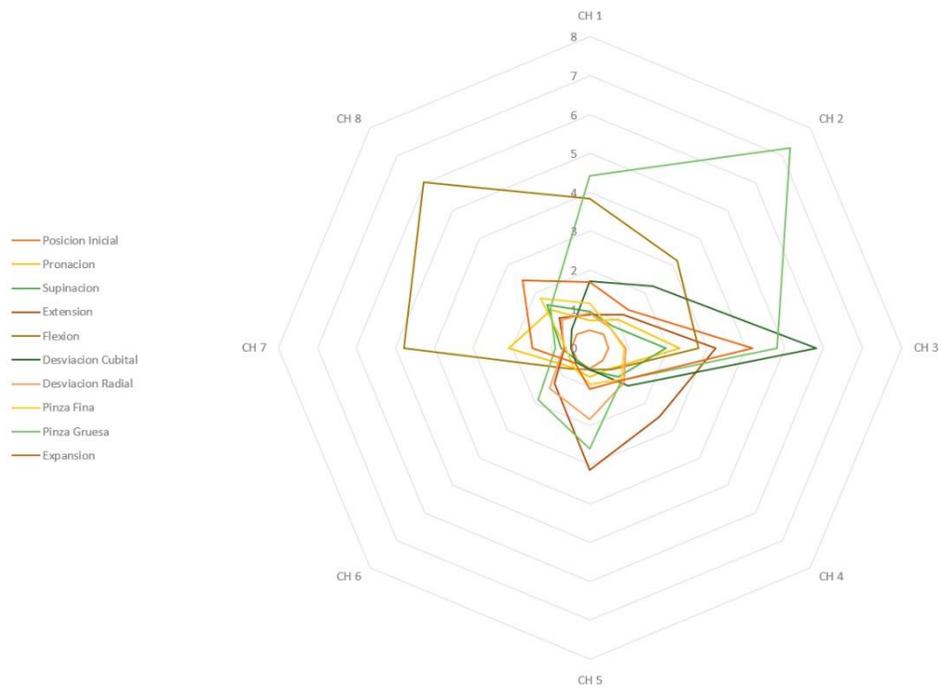


Fig. 4.41 (a). Gráfica Radial de Centroides de la característica MAV2 para el brazo derecho

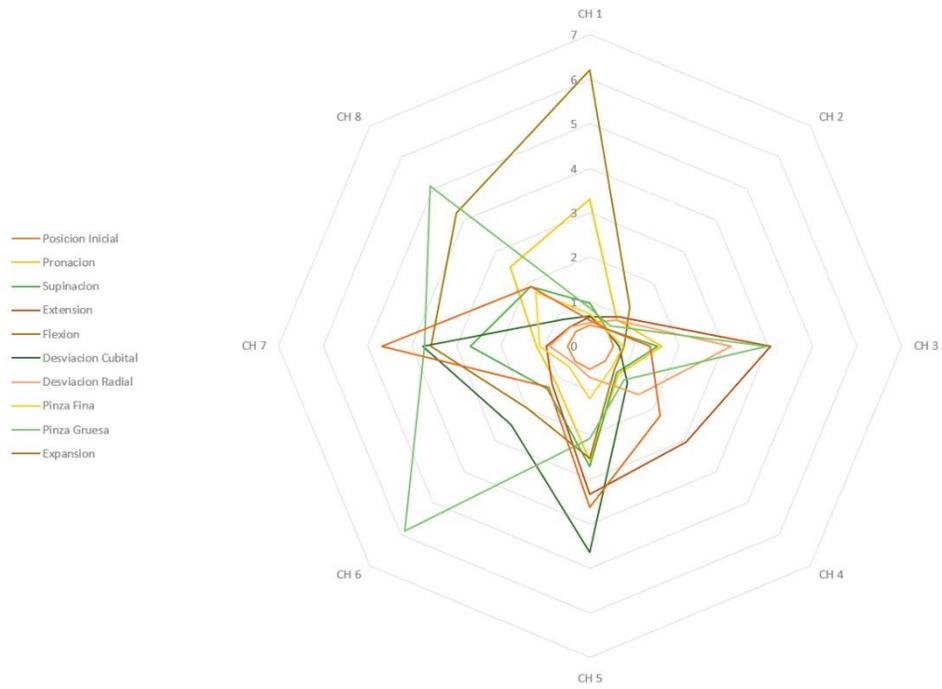


Fig. 4.41 (b). Gráfica Radial de Centroides de la característica MAV2 para el brazo izquierdo

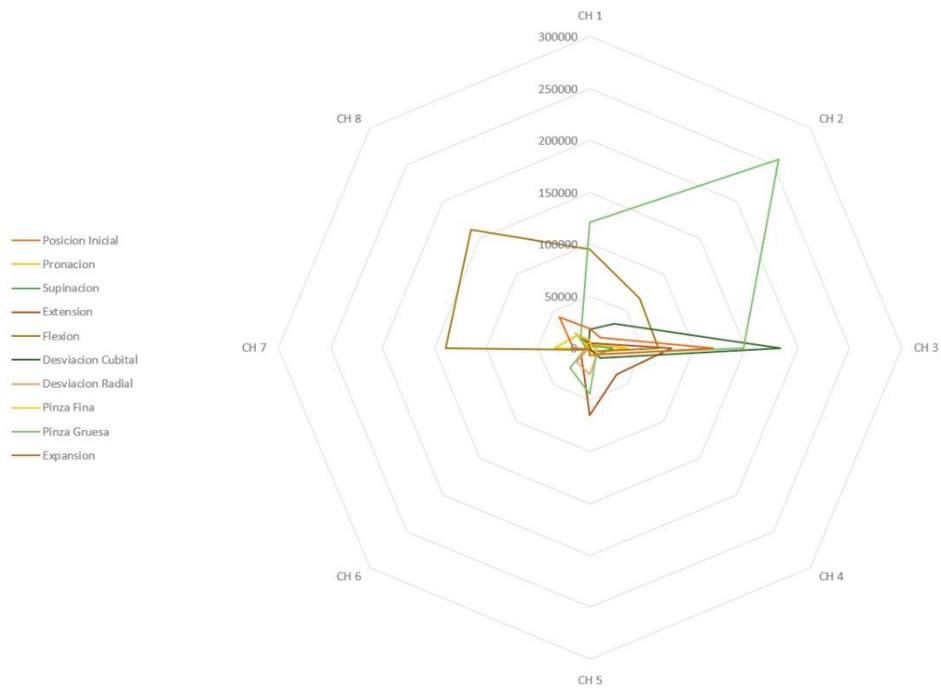


Fig. 4.42 (a). Gráfica Radial de Centroides de la característica MTW para el brazo derecho

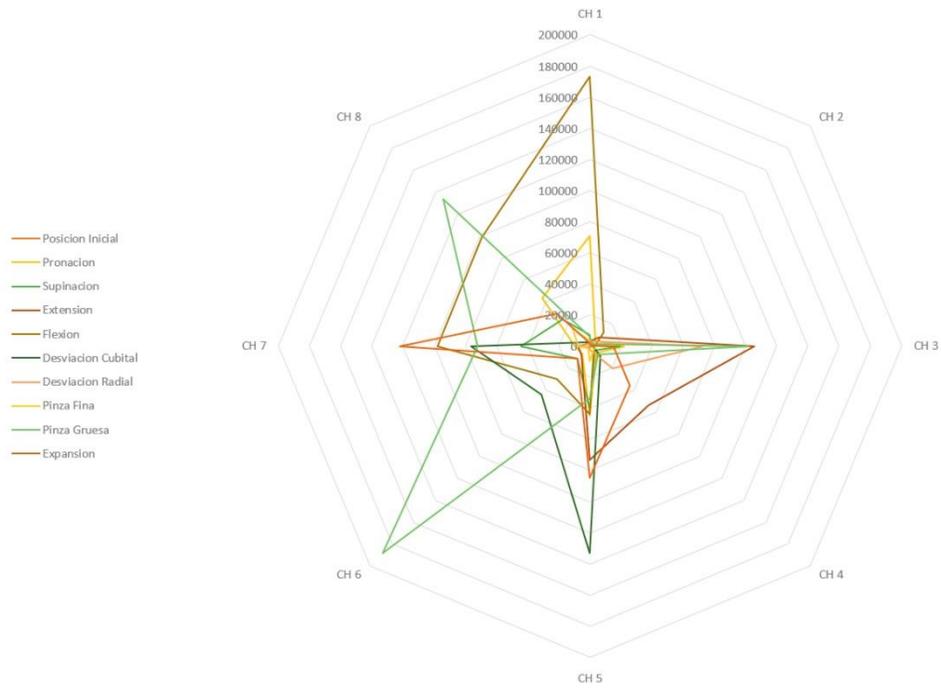


Fig. 4.42 (b). Gráfica Radial de Centroides de la característica MTW para el brazo izquierdo

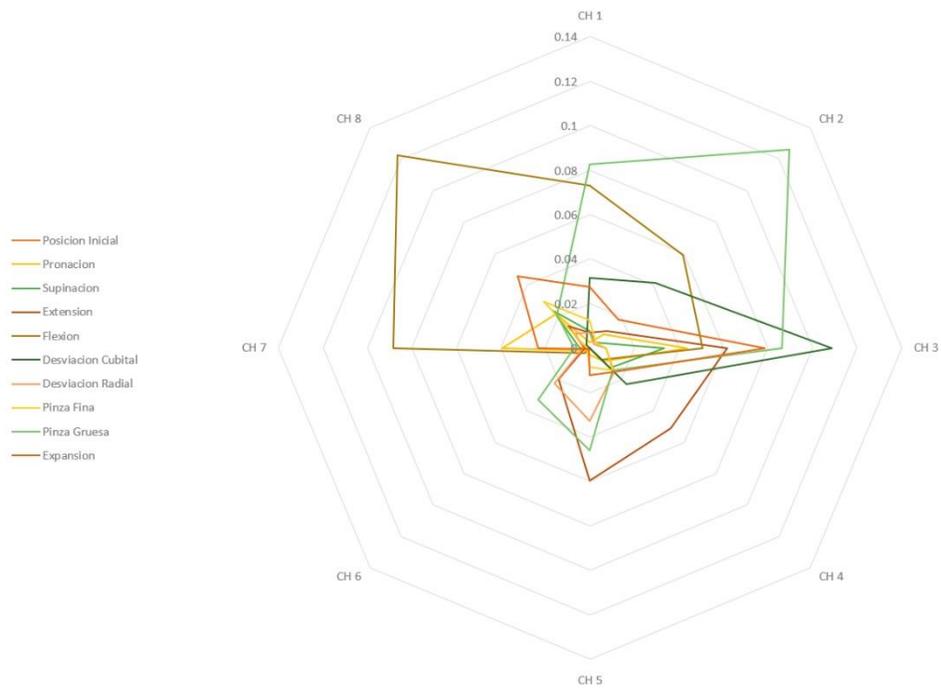


Fig. 4.43 (a). Gráfica Radial de Centroides de la característica MYOP para el brazo derecho

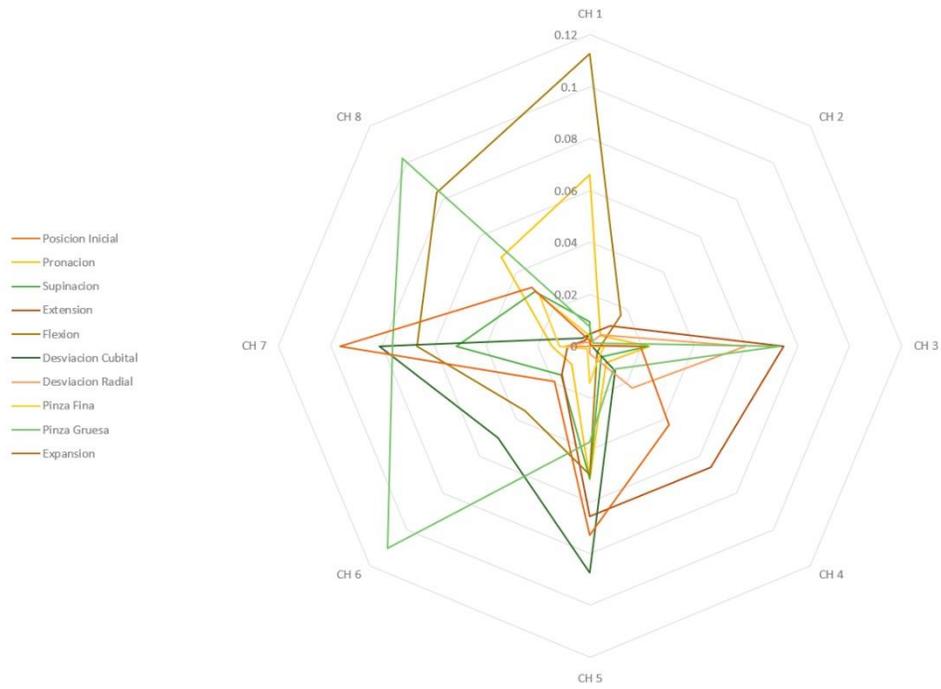


Fig. 4.43 (b). Gráfica Radial de Centroides de la característica MYOP para el brazo izquierdo

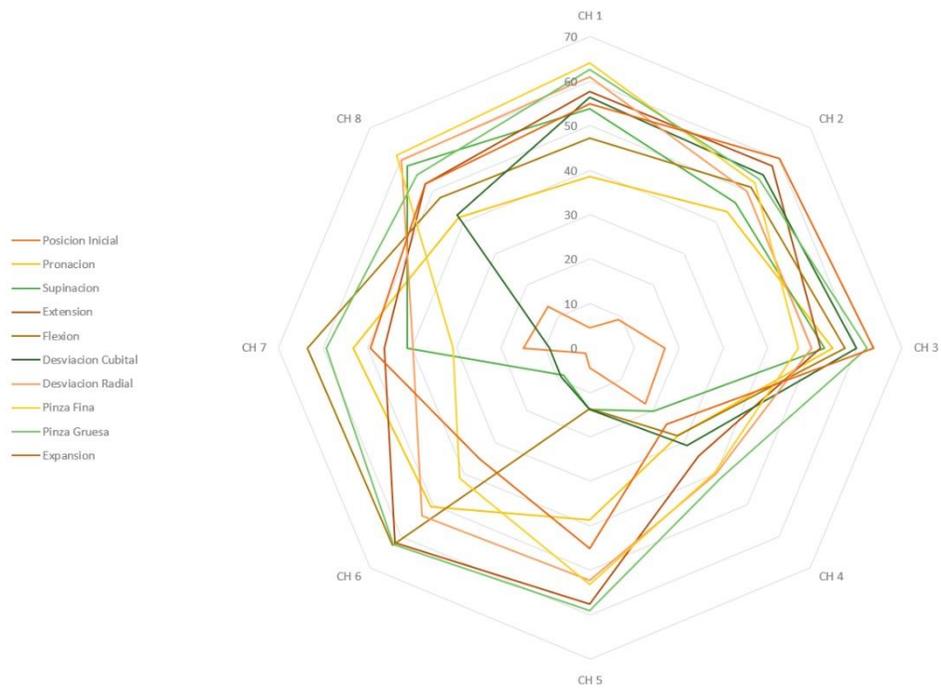


Fig. 4.44 (a). Gráfica Radial de Centroides de la característica PF para el brazo derecho

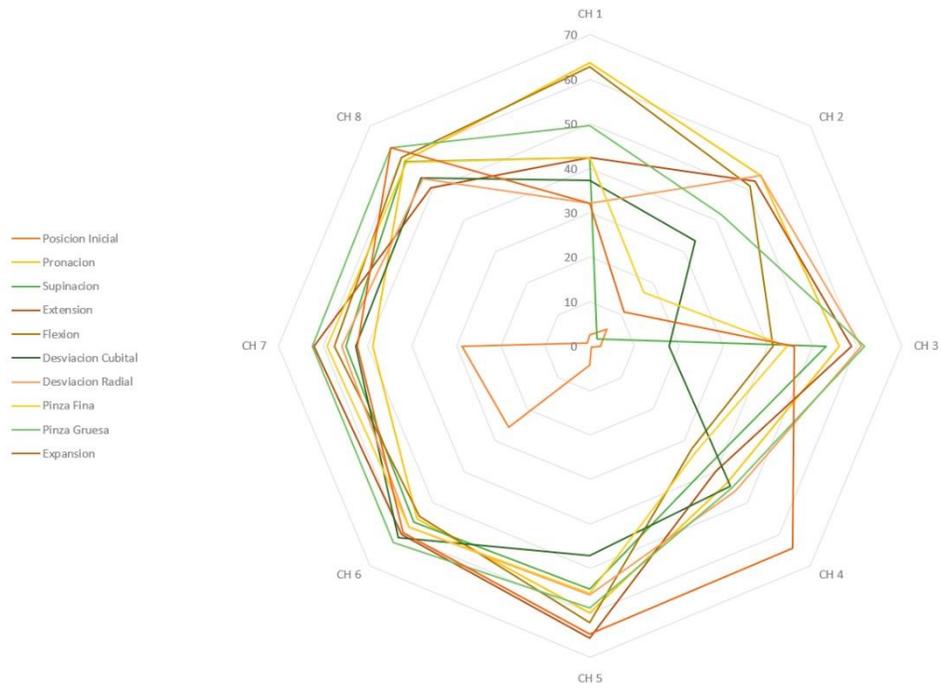


Fig. 4.44 (b). Gráfica Radial de Centroides de la característica PF para el brazo izquierdo

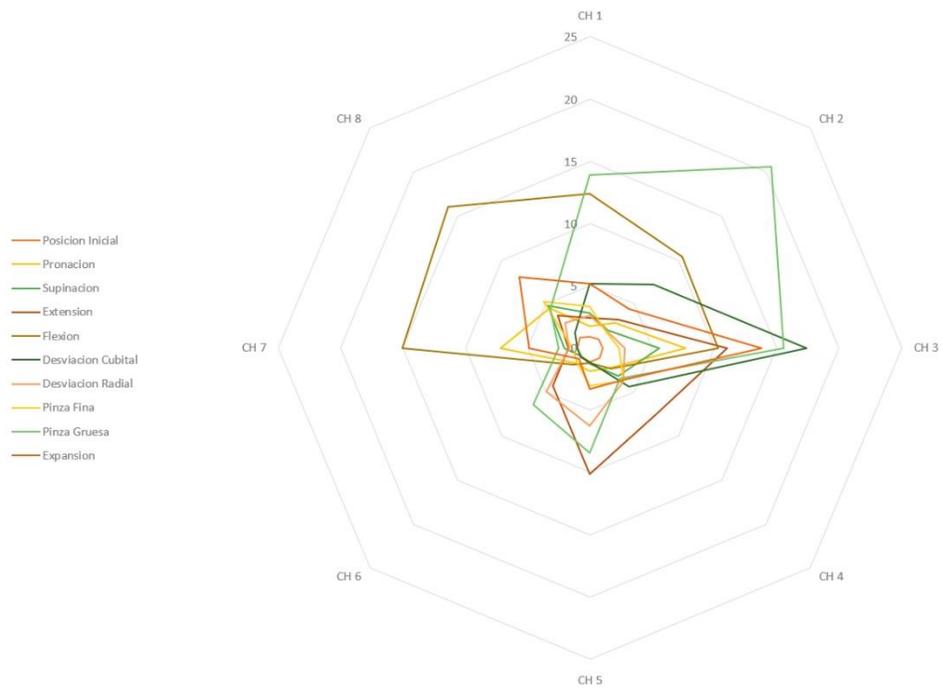


Fig. 4.45 (a). Gráfica Radial de Centroides de la característica RMS para el brazo derecho

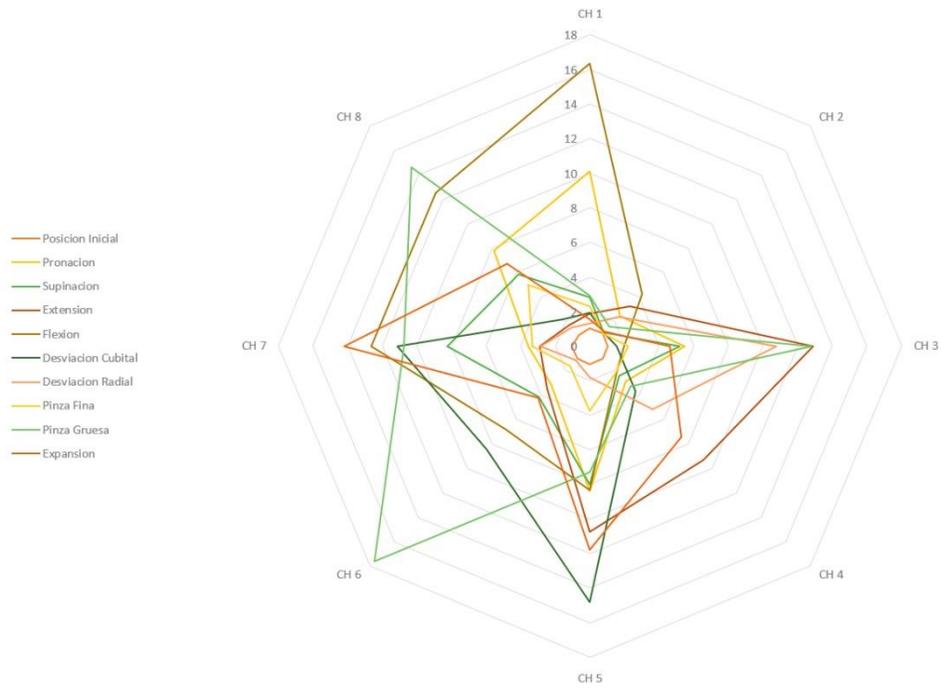


Fig. 4.45 (b). Gráfica Radial de Centroides de la característica RMS para el brazo izquierdo

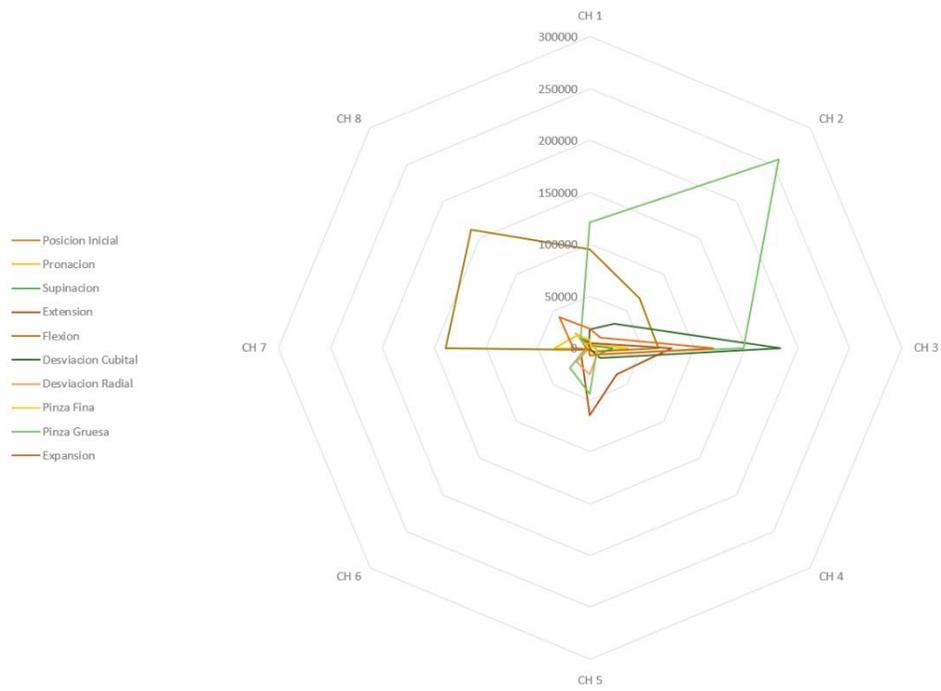


Fig. 4.46 (a). Gráfica Radial de Centroides de la característica SQI para el brazo derecho

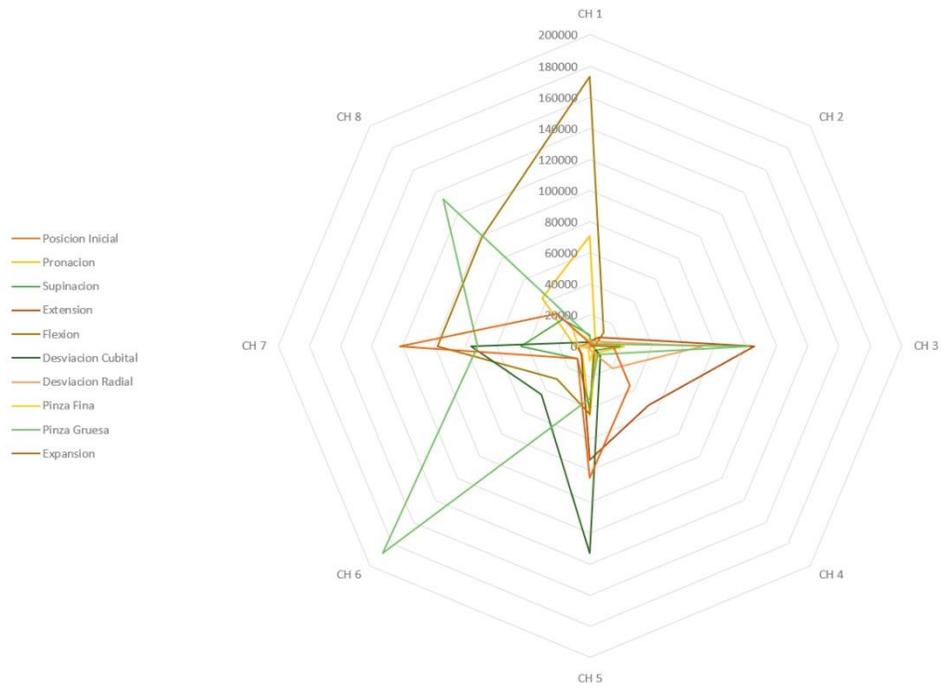


Fig. 4.46(b). Gráfica Radial de Centroides de la característica SQI para el brazo izquierdo

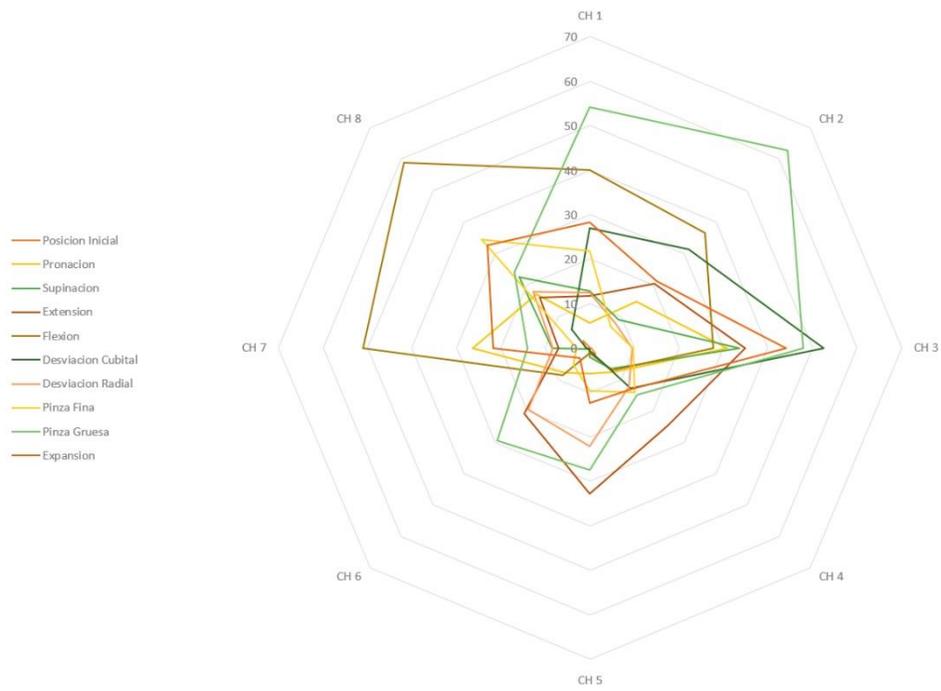


Fig. 4.47 (a). Gráfica Radial de Centroides de la característica SSC para el brazo derecho

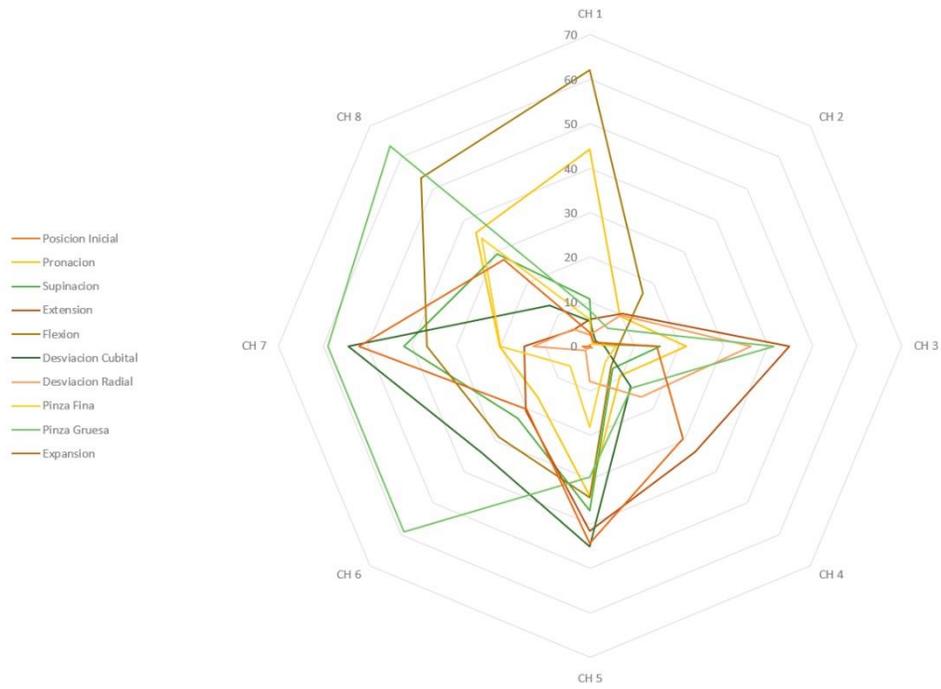


Fig. 4.47 (b). Gráfica Radial de Centroides de la característica SSC para el brazo izquierdo

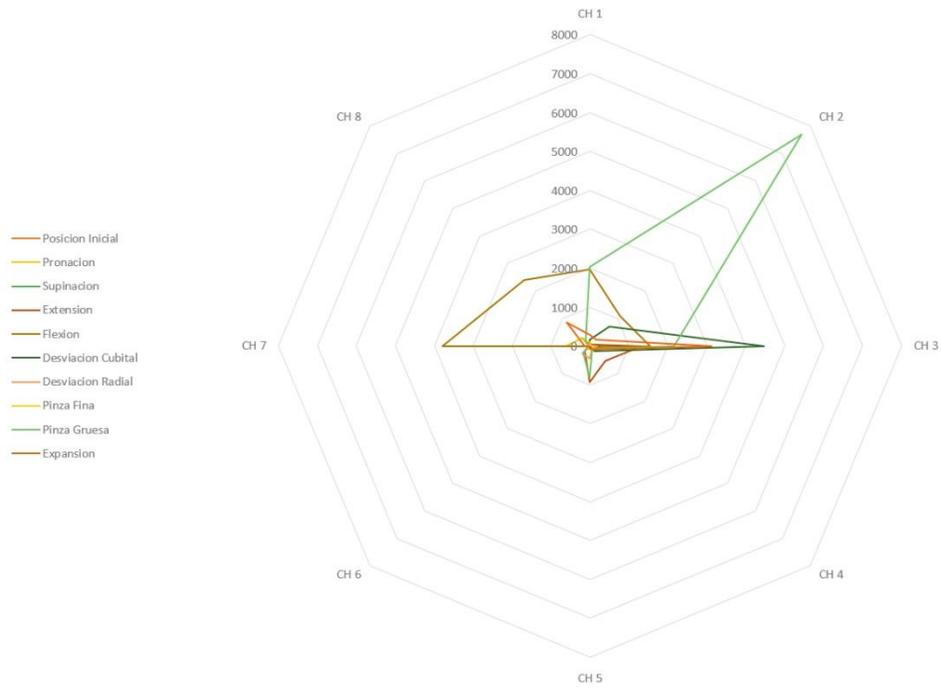


Fig. 4.48 (a). Gráfica Radial de Centroides de la característica TM3 para el brazo derecho

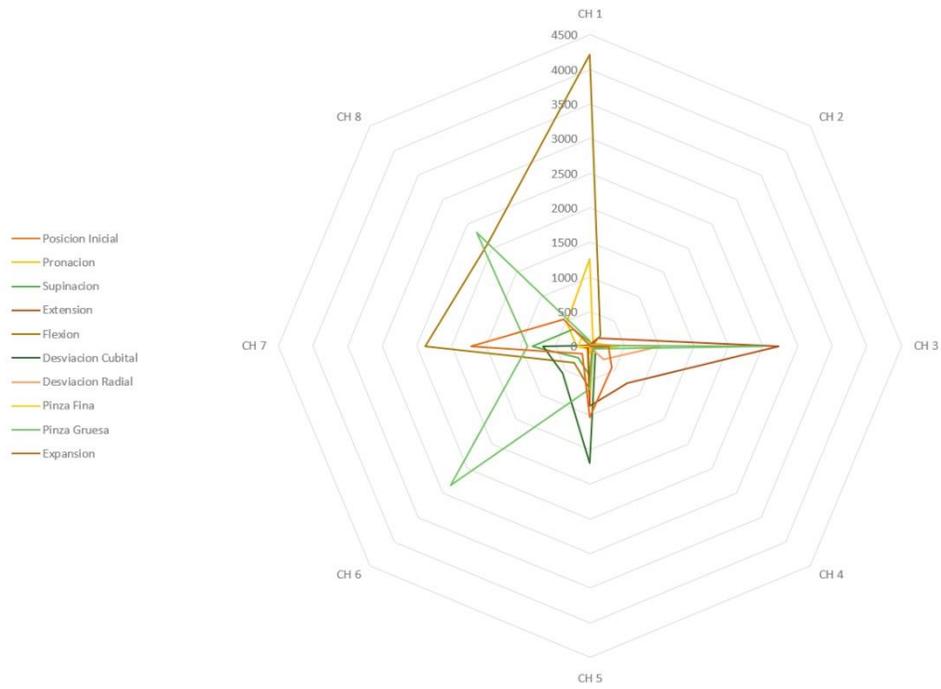


Fig. 4.48 (b). Gráfica Radial de Centroides de la característica TM3 para el brazo izquierdo

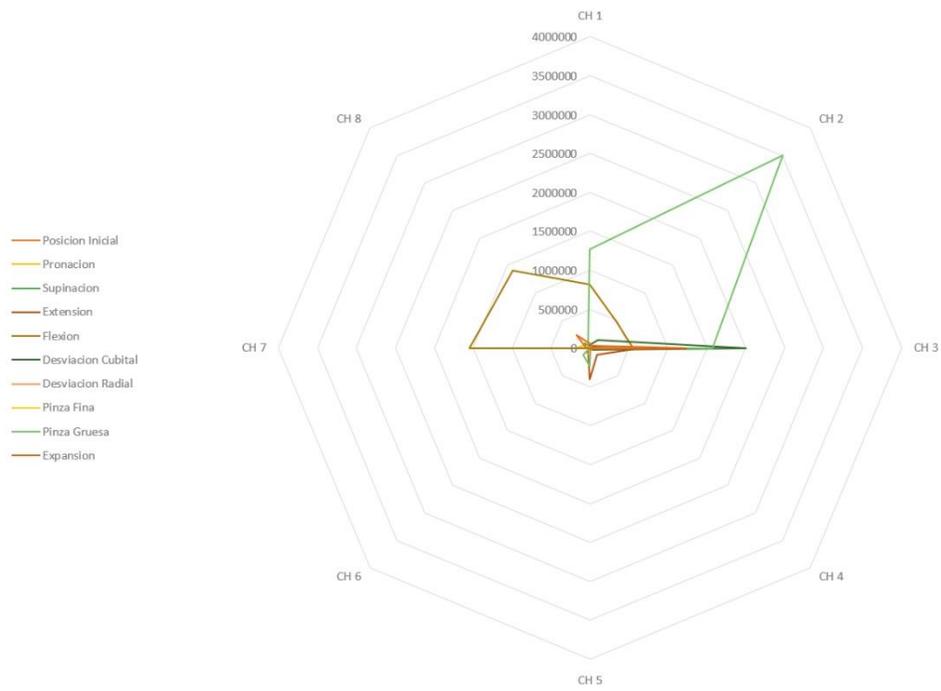


Fig. 4.49 (a). Gráfica Radial de Centroides de la característica TM4 para el brazo derecho

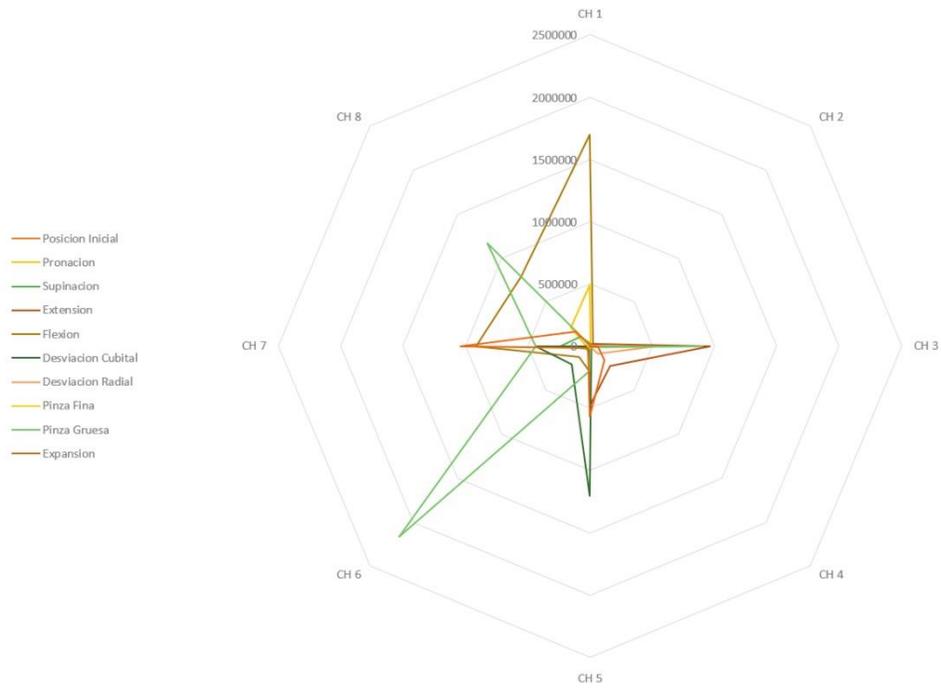


Fig. 4.49 (b). Gráfica Radial de Centroides de la característica TM4 para el brazo izquierdo

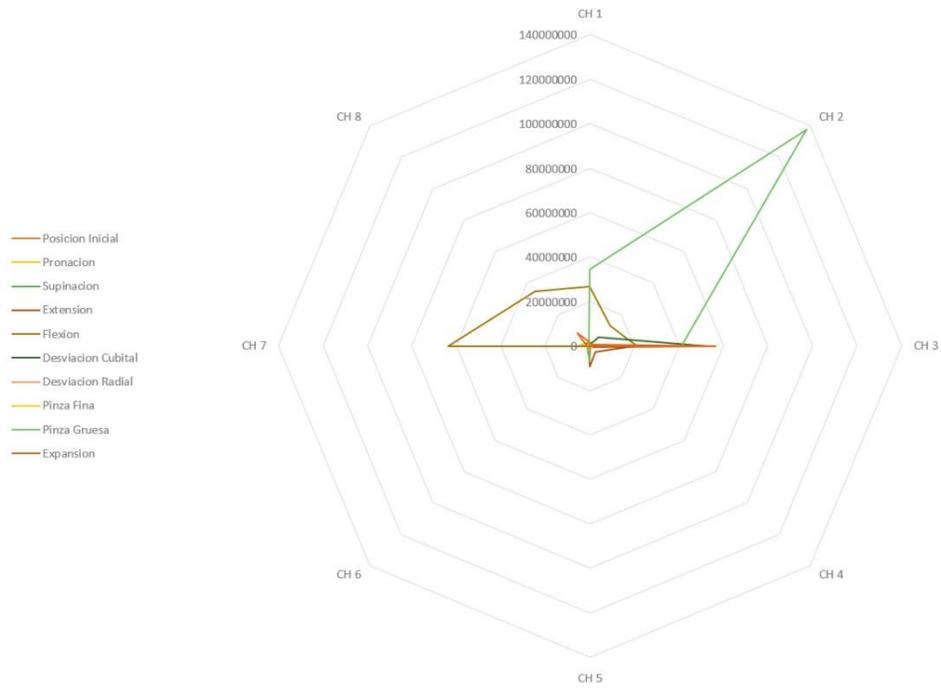


Fig. 4.50 (a). Gráfica Radial de Centroides de la característica TM5 para el brazo derecho

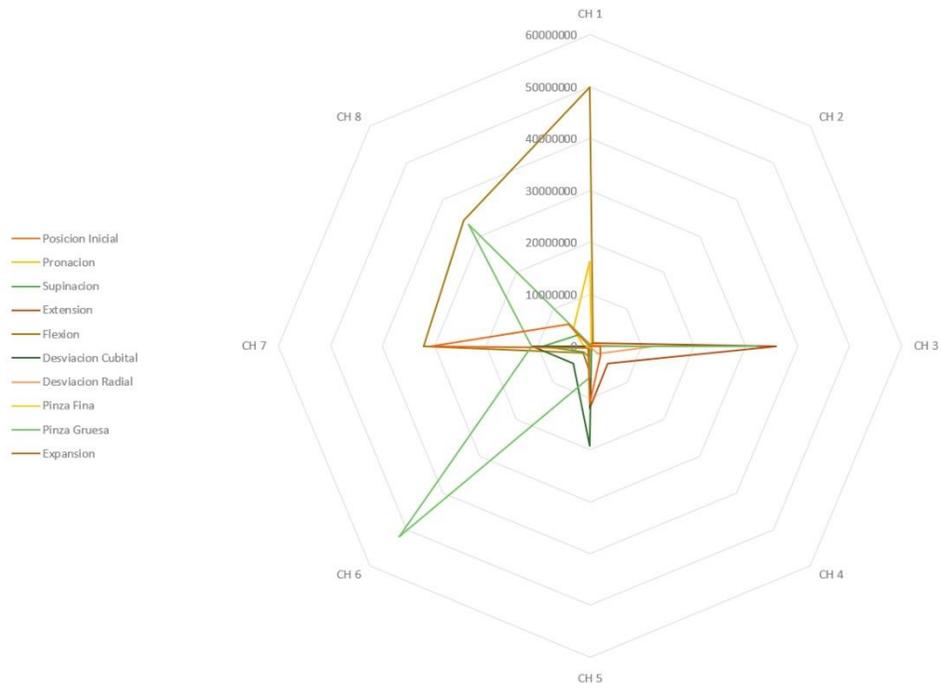


Fig. 4.50 (b). Gráfica Radial de Centroides de la característica TM5 para el brazo izquierdo

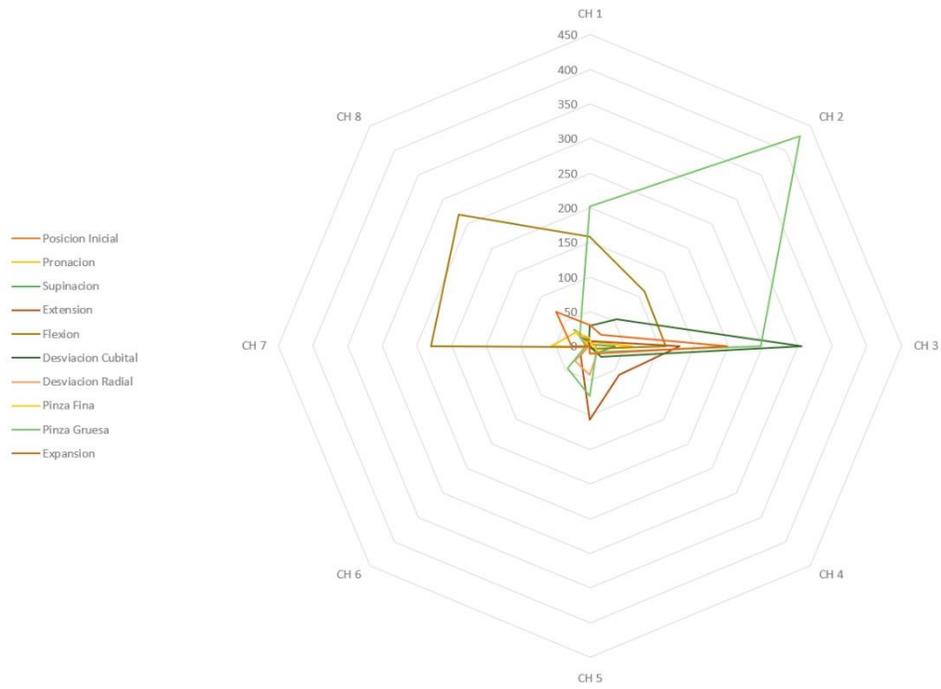


Fig. 4.51 (a). Gráfica Radial de Centroides de la característica VAR para el brazo derecho

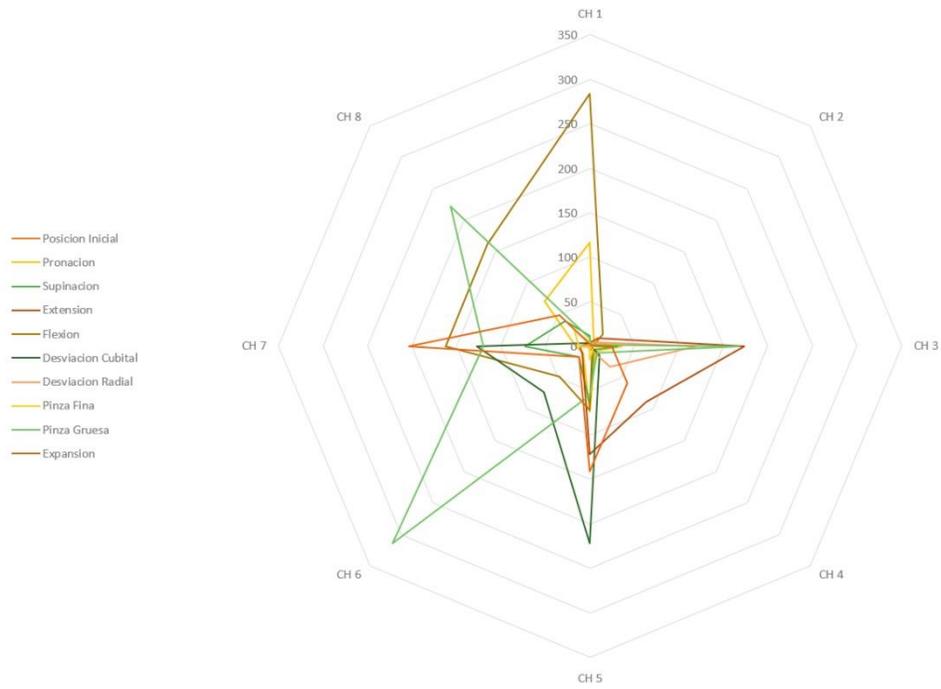


Fig. 4.51 (b). Gráfica Radial de Centroides de la característica VAR para el brazo izquierdo

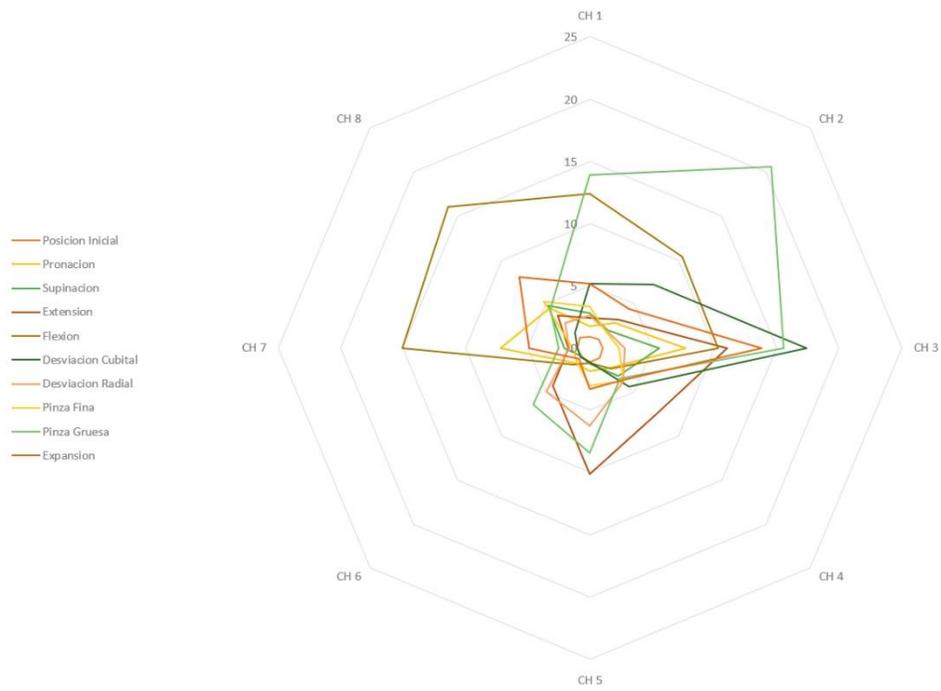


Fig. 4.52 (a). Gráfica Radial de Centroides de la característica VO para el brazo derecho

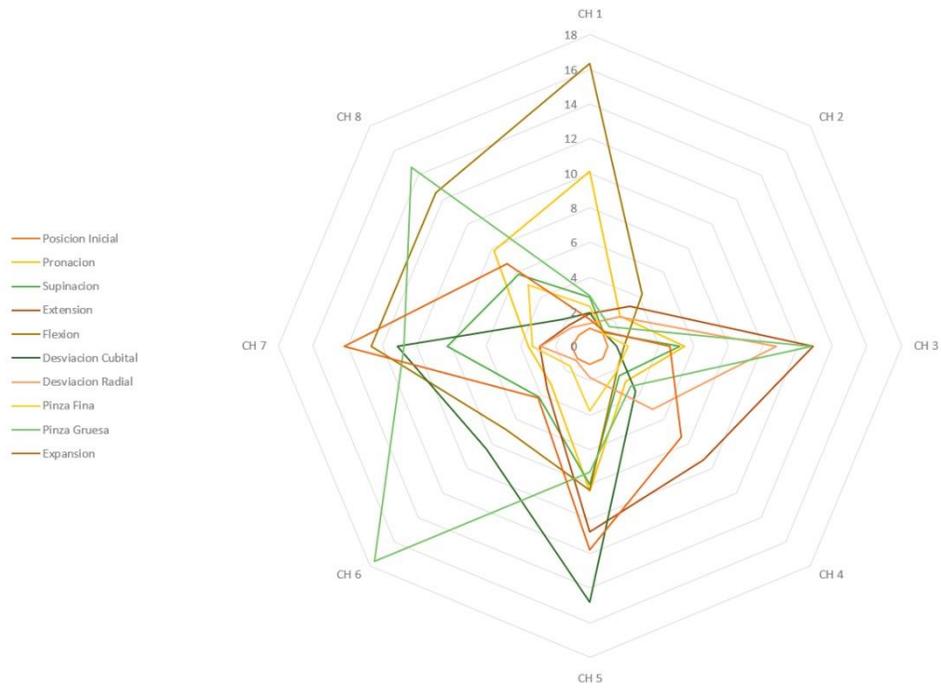


Fig. 4.52 (b). Gráfica Radial de Centroides de la característica VO para el brazo izquierdo

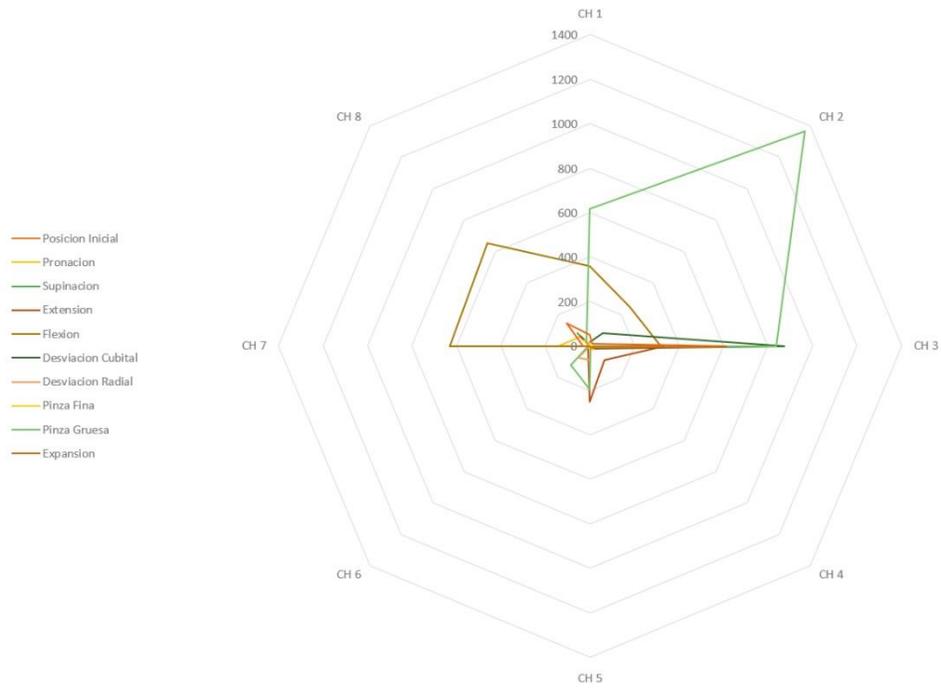


Fig. 4.53 (a). Gráfica Radial de Centroides de la característica WAMP para el brazo derecho

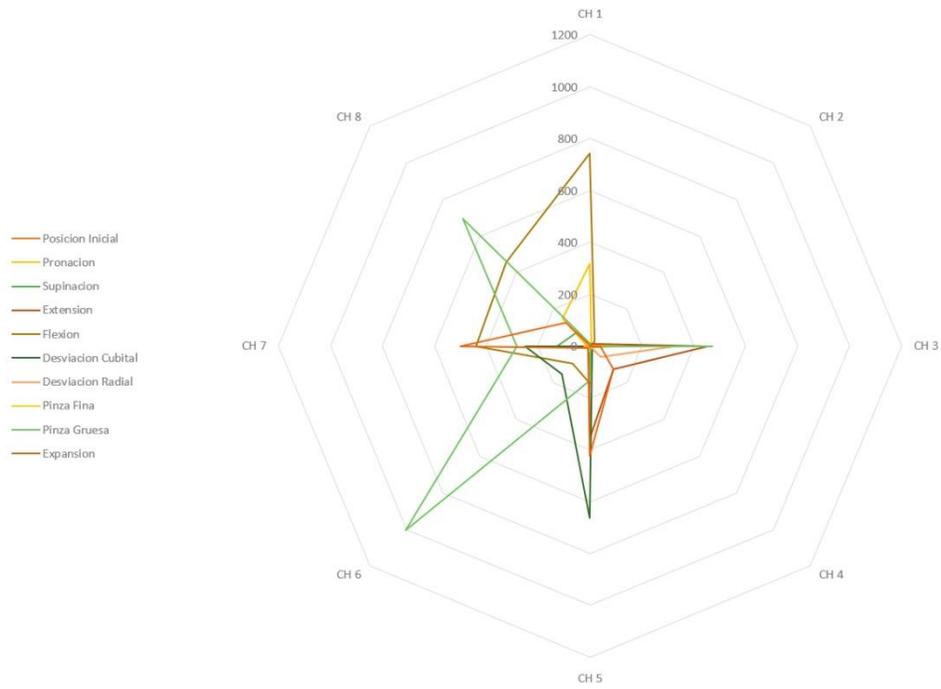


Fig. 4.53 (b). Gráfica Radial de Centroides de la característica WAMP para el brazo izquierdo

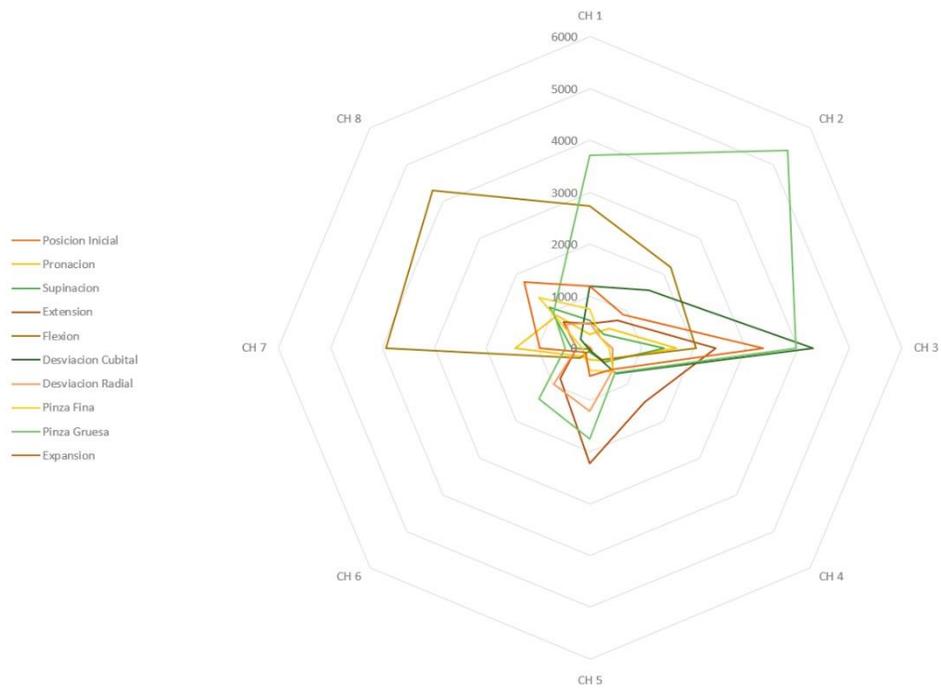


Fig. 4.54 (a). Gráfica Radial de Centroides de la característica WL para el brazo derecho

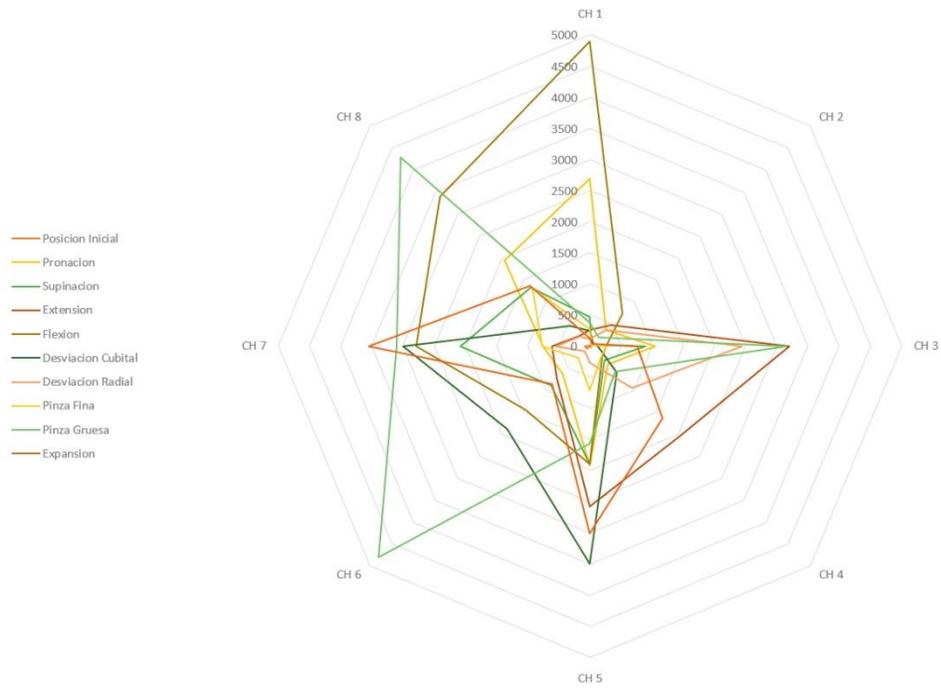


Fig. 4.54 (b). Gráfica Radial de Centroides de la característica WL para el brazo izquierdo

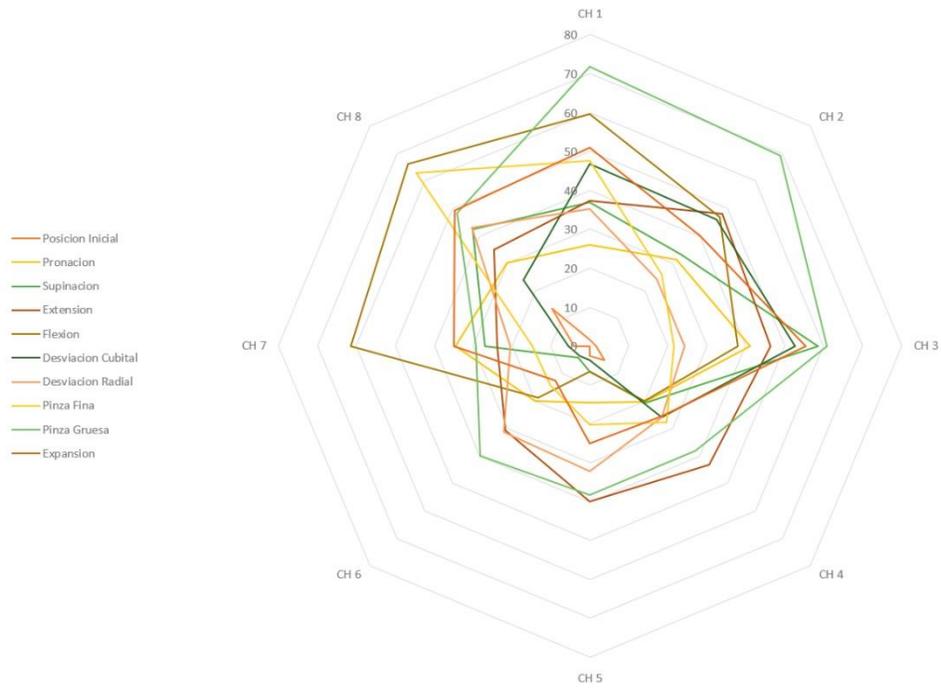


Fig. 4.55 (a). Gráfica Radial de Centroides de la característica ZC para el brazo derecho

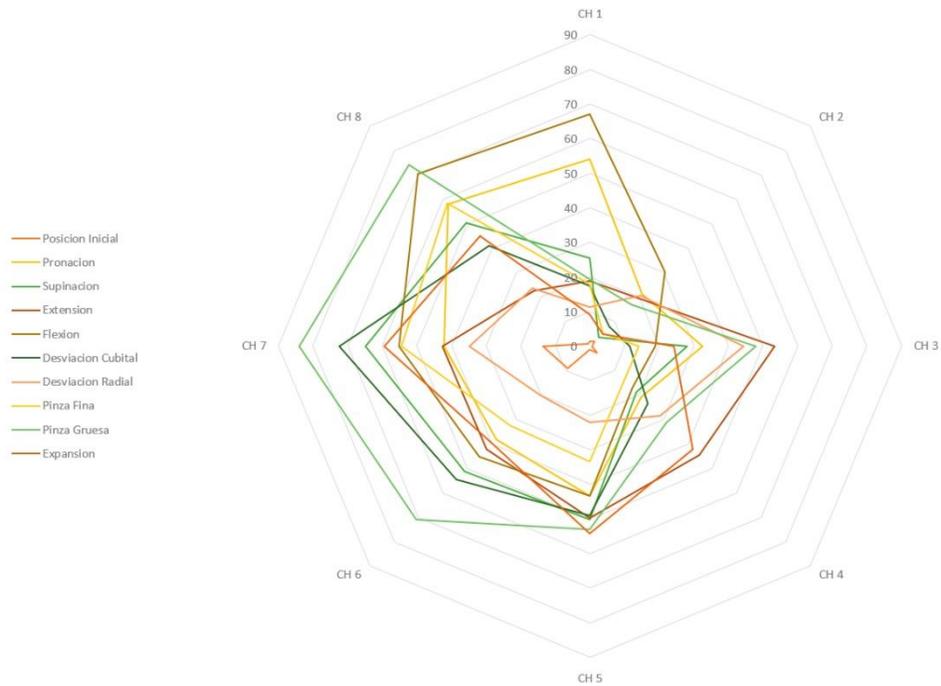


Fig. 4.55 (b). Gráfica Radial de Centroides de la característica ZC para el brazo izquierdo

Es observable en todas las gráficas que los movimientos con mayor intensidad son los movimientos ejecutados por los músculos flexores y extensores, mientras que los movimientos con menor intensidad son aquellos ejecutados por los músculos dedicados en la muñeca, gracias a esto se puede concluir que debido a la posición y sensores del brazalete es más fácil captar una señal nacida de un movimiento flexor o extensor que realizado por otro músculo.

Tabla 4.3. Agrupación de movimientos por amplitud de señal

<i>Movimientos de Alta Amplitud</i>	<i>Movimientos de Baja Amplitud</i>
<i>Flexión</i>	<i>Posición Inicial</i>
<i>Extensión</i>	<i>Pronación</i>
<i>Pinza Gruesa</i>	<i>Supinación</i>
<i>Expansión</i>	<i>Desviación Cubital</i>
	<i>Desviación Radial</i>
	<i>Pinza Fina</i>

Algunas características se encargan de normalizar la diferencia entre amplitudes, presentando un resultado muy homogéneo entre canales y movimientos, en contraparte el resto de las características que buscaban ampliar la diferencia de amplitud entre canales y movimientos, separando así en dos grupos nuestras características.

Finalmente, para comprobar que característica permitía una mejor clasificación de movimiento se calculó la eficacia, dado que al no poder distinguir de un verdadero positivo a un verdadero negativo es imposible calcular la sensibilidad o

especificidad. Como resultado de varias ejecuciones del programa la eficacia de cada atributo puede observarse en la siguiente gráfica.

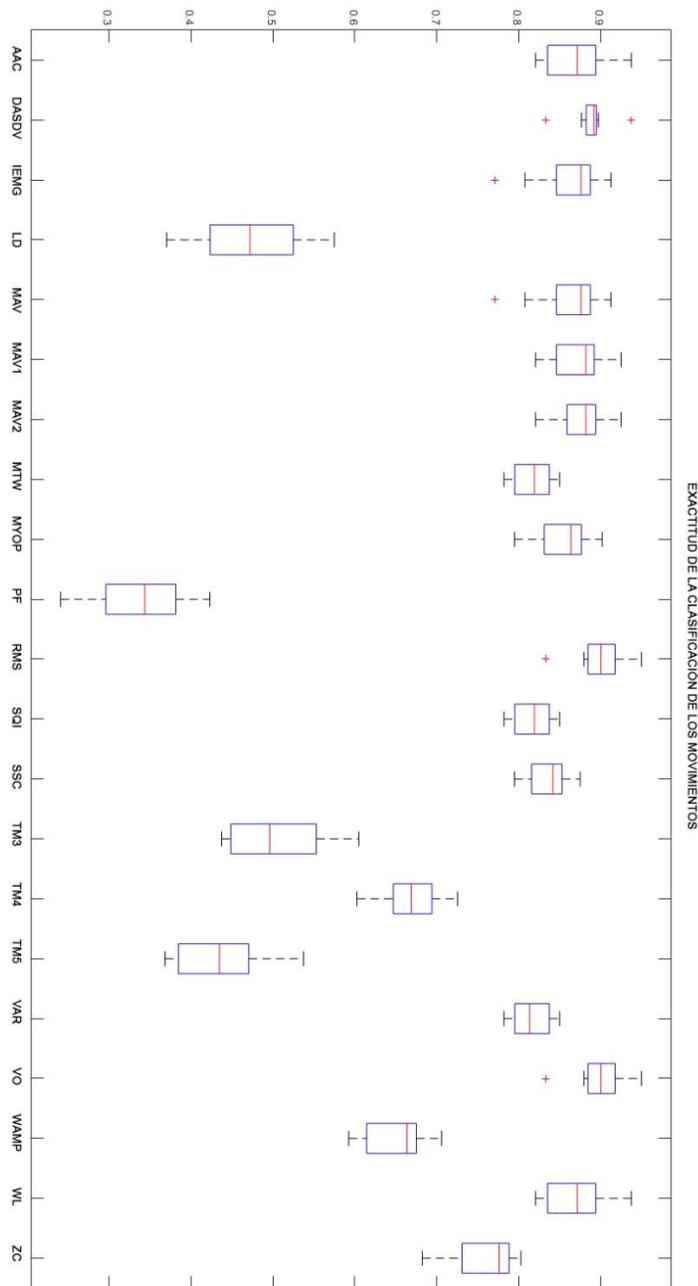


Fig. 4.56. Gráfica Boxplot con los resultados de la eficacia de clasificación por atributo, se observa que RMS, DASDV y VO son los mejores atributos para realizar una clasificación.

En la tabla 4.4 se puede observar los atributos ordenados por mayor a menor eficacia.

Para calcular la distribución de la precisión, se utilizó el rango intercuartílico:

$$R_I = Q_3 - Q_1, \quad (4.1)$$

donde $Q_3 - Q_1$ representa el tercer y primer cuartil respectivamente.

Entre mas pequeño sea el valor de R_I implica una menor distribución de la eficacia de la distribución.

Mientras DASDV presenta la mayor eficacia y menor R_I se asume que es el atributo que mejor se acopla a nuestro experimento, mientras que RMS y VO aunque presentan una ligera mejora en la eficacia, su R_I es también ligeramente mayor.

Tabla 4.4. Agrupación de movimientos por amplitud de señal

Atributo	Q_1	<i>Mediana Eficacia</i>	Q_3	R_I
DASDV	0.881	0.9	0.895	0.014
RMS	0.883	0.901	0.919	0.036
VO	0.883	0.901	0.919	0.036
MAV1	0.842	0.882	0.893	0.051
MAV2	0.858	0.882	0.897	0.039
IEMG	0.837	0.876	0.888	0.051
MAV	0.837	0.876	0.888	0.051
AAC	0.835	0.871	0.899	0.064
WL	0.835	0.871	0.899	0.064
MYOP	0.829	0.864	0.882	0.053
SSC	0.812	0.842	0.857	0.045
MTW	0.795	0.819	0.839	0.044
SQI	0.795	0.819	0.839	0.044
VAR	0.795	0.813	0.839	0.044
ZC	0.728	0.776	0.79	0.062
TM4	0.643	0.669	0.697	0.054
WAMP	0.611	0.664	0.677	0.066
TM3	0.448	0.496	0.562	0.114
LD	0.423	0.472	0.532	0.109
TM5	0.382	0.435	0.474	0.092
PF	0.293	0.344	0.386	0.093

5. CONCLUSIONES

El presente trabajo se encargó de presentar las señales EMG, origen y uso, las diferentes herramientas para su extracción, la creación de un protocolo propio basado en las consideraciones éticas planteadas en el tratado de Pautas Éticas Internacionales para la Investigación Biomédica en Seres Humanos para la adquisición de las señales en un grupo de estudio previamente establecido, así como la metodología para el procesamiento de las señales, limpieza, extracción de características y posteriormente clasificación mediante algoritmos de aprendizaje automático. Se describen las familias para la transformada wavelet, así como la función *wavelet denoising* para el filtrado y los valores que funcionan mejor para el tipo de señales adquiridas por sEMG. Se realiza una comparativa de las diferentes características que se pueden obtener de una señal EMG y aquellas que tienen un mejor funcionamiento para la clasificación mediante un análisis radial de características con KNN y K-Means.

La motivación de este trabajo se basa en el trabajo que realizan los fisioterapeutas para la rehabilitación física de los pacientes, y en un futuro poder presentar una herramienta que sirva como auxiliar en su trabajo, a pesar de ello no el trabajo realizado sirve como base para cualquier futuro proyecto basado en reconocimiento de gestos (*gesture recognition*).

Se propone que esta investigación sirva como base para futuro trabajo para trabajos utilizando técnicas como *Rough Sets*, *Support Vector Machine*, *Deep Learning*, etc. que permitan un mejor entendimiento y clasificación de las señales EMG.

Finalmente se presenta el conjunto de información público para cualquier persona que desee hacer uso de las señales para seguir aportando nuevo conocimiento (Ramírez Ángeles, I. J.; Aceves Fernández, M. A., 2018).

REFERENCIAS

Asghari Oskoei, M., & Hu, H. (2007). Myoelectric control systems-A survey. *Biomedical Signal Processing and Control*, 2(4), 275–294. <https://doi.org/10.1016/j.bspc.2007.07.009>.

Baratloo, A., Hosseini, M., Negida, A., & El Ashal, G. (2015). Part 1: simple definition and calculation of accuracy, sensitivity and specificity.

Bezdek, J. C., Ehrlich, R., & Full, W. (1984). FCM: The fuzzy c-means clustering algorithm. *Computers & Geosciences*, 10(2-3), 191-203.

Boostani, R., & Moradi, M. H. (2003). Evaluation of the forearm EMG signal features for the control of a prosthetic hand. *Physiological measurement*, 24(2), 309.

Canal, M. R. (2010). Comparison of wavelet and short time Fourier transform methods in the analysis of EMG signals. *Journal of medical systems*, 34(1), 91-94.

Chou, K. C., & Shen, H. B. (2006). Predicting eukaryotic protein subcellular location by fusing optimized evidence-theoretic K-nearest neighbor classifiers. *Journal of Proteome Research*, 5(8), 1888-1897.

Chowdhury, R., Reaz, M., Ali, M., Bakar, A., Chellappan, K., & Chang, T. (2013). Surface Electromyography Signal Processing and Classification Techniques. *Sensors*, 13(9), 12431–12466. <https://doi.org/10.3390/s130912431>.

Cortés, J. A., Medina, F. A., & Chaves, J. A. (2007). Del análisis de fourier a las wavelets análisis de fourier. *Scientia et technica*, 1(34).

Costa, David & Duarte, Carlos. (2015). From One to Many Users and Contexts: A Classifier for Hand and Arm Gestures. *International Conference on Intelligent User Interfaces, Proceedings IUI. 2015*. 10.1145/2678025.2701388.

Costanzo, L. S. (2011). *Fisiología Celular*, Elsevier.

De Luca, C. J., LeFever, R. S., McCue, M. P., & Xenakis, A. P. (1982). Behaviour of human motor units in different muscles during linearly varying contractions. *The Journal of physiology*, 329(1), 113-128.

Du, S., & Vuskovic, M. (2004). Temporal vs. spectral approach to feature extraction from prehensile EMG signals. In *Proceedings of IEEE International Conference on Information Reuse and Integration* (pp. 344–350).

Engelbrecht, Andries P. (2007). *Introduction to Computational Intelligence*.

Englehart, K., Hudgins, B., Parker, P. A., & Stevenson, M. (1999). Classification of the myoelectric signal using time-frequency based representations. *Medical engineering & physics*, 21(6-7), 431-438.

Favaloro, A. D. R. (2008). Pautas éticas internacionales para la investigación biomédica en seres humanos. *Index Infectológico*, 13.

Forrest, P. (1996). *The identity of indiscernibles*.

Fougner, A. (2007). Proportional myoelectric control of a multifunction upper limb prosthesis. Master's Thesis, Norwegian University of Science and Technology, Trondheim, Norway.

Fougner, A. L. (2007). Proportional myoelectric control of a multifunction upper-limb prosthesis (Master's thesis, Institutt for teknisk kybernetikk).

Gandhi, T., Panigrahi, B. K., & Anand, S. (2011). A comparative study of wavelet families for EEG signal classification. *Neurocomputing*, 74(17), 3051–3057.

Guyon, I., & Elisseeff, A. (2003). An introduction to variable and feature selection. *Journal of machine learning research*, 3(Mar), 1157-1182.

Hartigan, J. A., & Wong, M. A. (1979). Algorithm AS 136: A k-means clustering algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, 28(1), 100-108.

Huang, H.P., & Chen, C.Y. (1999). Development of a myoelectric discrimination system for a multi-degree prosthetic hand. In *Proceedings of IEEE International Conference on Robotics and Automation (Vol. 3, pp. 2392–2397)*.

Hudgins, B., Parker, P., & Scott, R. (1993). A new strategy for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, 40(1), 82–94.

Kim, K. S., Choi, H. H., Moon, C. S., & Mun, C. W. (2011). Comparison of k-nearest neighbor, quadratic discriminant and linear discriminant analysis in classification of electromyogram signals based on the wrist-motion directions. *Current Applied Physics*, 11(3), 740–745.

Kim, K. S., Choi, H. H., Moon, C. S., & Mun, C. W. (2011). Comparison of k-nearest neighbor, quadratic discriminant and linear discriminant analysis in classification of electromyogram signals based on the wrist-motion directions. *Current applied physics*, 11(3), 740-745.

Kolahdouzan, M., & Shahabi, C. (2004). Voronoi-based k nearest neighbor search for spatial network databases. In *Proceedings of the Thirtieth international conference on Very large data bases-Volume 30 (pp. 840-851)*. VLDB Endowment.

Komorowski, J., Polkowski, L., & Skowron, A. (1999). Rough Sets: A tutorial. *Rough Fuzzy Hybridization: A New Trend in Decision-Making*, 3–98. <https://doi.org/10.1111/0824-7935.00159>

Maćkiewicz, A., & Ratajczak, W. (1993). Principal components analysis (PCA). *Computers & Geosciences*, 19(3), 303-342.

Merletti, R. (1996). Standards for reporting EMG data. *Journal of Electromyography and Kinesiology*, 6(1), III–IV.

Merletti, R., Parker, P. J. (2004). *Electromyography: Physiology, Engineering, and Non-Invasive Applications*. Wiley-IEEE Press.

Myo (2016). Disponible en: <https://www.myo.com/techspecs>.

Nilsson, N. J. (1980). *Principles of Artificial Intelligence*, Morgan Kaufmann Publishers.

Oskoei, M. A., & Hu, H. (2008). Support vector machine-based classification scheme for myoelectric control applied to upper limb. *IEEE Trans. Biomed. Engineering*, 55(8), 1956-1965.

Oskoei, M. A., & Hu, H. (2008). Support vector machine-based classification scheme for myoelectric control applied to upper limb. *IEEE Trans. Biomed. Engineering*, 55(8), 1956-1965.

Pandey, B., & Mishra, R. B. (2009). An integrated intelligent computing model for the interpretation of EMG based neuromuscular diseases. *Expert Systems with Applications*, 36(5), 9201–9213.

Park, H. S., & Jun, C. H. (2009). A simple and fast algorithm for K-medoids clustering. *Expert systems with applications*, 36(2), 3336-3341.

Pawlak, Z. (1982). Rough sets. *International journal of computer & information sciences*, 11(5), 341-356.

Philipson, L. (1987). *The electromyographic signal used for control of upper extremity prostheses and for quantification of motor blockade during epidural anaesthesia*. Ph.D. Thesis, Linköping University, Linköping, Sweden.

Phinyomark, A., Limsakul, C., & Phukpattaranont, P. (2009). A novel feature extraction for robust EMG pattern recognition. arXiv preprint arXiv:0912.3973.

Phinyomark, A., Limsakul, C., & Phukpattaranont, P. (2009). An optimal wavelet function based on wavelet denoising for multifunction myoelectric control. In *Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, 2009. ECTI-CON 2009. 6th International Conference on* (Vol. 2, pp. 1098-1101). IEEE.

Proakis, J. G. (2001). *Digital signal processing: principles algorithms and applications*. Pearson Education India.

Ramírez Ángeles, I. J.; Aceves Fernández, M. A. (2018), "Multi-Channel Electromyography Signal Acquisition of Forearm", Mendeley Data, v1

<http://dx.doi.org/10.17632/p77jn92bzg.1>

Russell, S. J., & Norvig, P. (2016). *Artificial intelligence: a modern approach*. Malaysia; Pearson Education Limited.

Saridis, G. N., & Gootee, T. P. (1982). EMG pattern analysis and classification for a prosthetic arm. *IEEE Transactions on Biomedical Engineering*, BME-29(6), 403–412.

Smith, L. I. (2002). *A tutorial on principal components analysis*.

Tkach, D., Huang, H., & Kuiken, T. A. (2010). Study of stability of time-domain features for electromyographic pattern recognition. *Journal of NeuroEngineering and Rehabilitation*, 7(21). doi:10.1186/1743-0003-7-21.

Tkach, D., Huang, H., & Kuiken, T. A. (2010). Study of stability of time-domain features for electromyographic pattern recognition. *Journal of neuroengineering and rehabilitation*, 7(1), 21.

Turing, A. M. (2009). Computing machinery and intelligence. In *Parsing the Turing Test* (pp. 23-65). Springer, Dordrecht.

World Confederation for Physical Therapy. (2011). Policy statement: description of physical therapy.

Zardoshti-Kermani, M., Wheeler, B. C., Badie, K., & Hashemi, R. M. (1995). EMG feature evaluation for movement control of upper extremity prostheses. *IEEE Transactions on Rehabilitation Engineering*, 3(4), 324–333.

Zardoshti-Kermani, M., Wheeler, B. C., Badie, K., & Hashemi, R. M. (1995). EMG feature evaluation for movement control of upper extremity prostheses. *IEEE Transactions on Rehabilitation Engineering*, 3(4), 324-333.

Zhang, M. L., & Zhou, Z. H. (2007). ML-KNN: A lazy learning approach to multi-label learning. *Pattern recognition*, 40(7), 2038-2048.

APÉNDICE

Carta de Consentimiento



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE INGENIERÍA
CARTA DE CONSENTIMIENTO



Santiago de Querétaro, Querétaro., a ____ de _____ del 20 ____

FICHA DE IDENTIFICACIÓN

N° REGISTRO			
NOMBRE COMPLETO			
FECHA DE NACIMIENTO			
SEXO	M	F	O
LATERALIDAD	Diestro	Zurdo	Ambidiestro
DATOS DE CONTACTO			

CRITERIOS DE INCLUSIÓN

EMBARAZO		LACTANCIA		ALTERACIONES NEUROMUSCULARES	
S	N	S	N	S	N

ANTECEDENTES HEREDOFAMILIARES	
FARMACOLOGÍA	
ANTECEDENTES PERSONALES PATOLÓGICOS	
CONOCIMIENTO DEL ENTORNO	<p>TOXICOMANÍAS:</p> <p>ACTIVIDAD FÍSICA:</p> <p>HOBBIES:</p> <p>ALIMENTACIÓN:</p> <p>BEBIDAS ENERGIZANTES O CON CAFEÍNA:</p> <p>HORAS DE SUEÑO:</p>

He sido invitado de manera libre y sin coerción alguna, a participar de forma completamente voluntaria como participante de estudio en el proyecto denominado "Detección Y Clasificación De Señales Mieléctricas En El



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE INGENIERÍA
CARTA DE CONSENTIMIENTO



Brazo Mediante El Uso De Algoritmos Basados En Inteligencia Artificial” registrado ante la Universidad Autónoma de Querétaro. Entiendo que las pruebas realizadas serán para el registro de mis señales mioeléctricas, para esto, se usará un brazalete electromiográfico no invasivo colocado en mi antebrazo para la adquisición de todos los datos. Declaro que he sido informado sobre los posibles riesgos, inconvenientes molestias y beneficios derivados de mi participación en el estudio son mínimos y poco comunes y de que antes de realizar las pruebas reales se hará una prueba de adaptación para evitarlos. Soy consciente de que no habrá beneficios para mi persona y que no se me recompensará económicamente. Se me ha proporcionado el nombre de los investigadores responsables que puede ser fácilmente contactado dentro de la institución universitaria para cualquier duda o inquietud, quienes se han comprometido a darme la información oportuna sobre cualquier duda, pregunta o aclaración. He leído o me ha sido leída la información proporcionada la cual he comprendido. He tenido la oportunidad de preguntar sobre ella y se me ha contestado satisfactoriamente las preguntas que he realizado. Consiento voluntariamente participar en esta investigación como participante y entiendo que tengo el derecho de retirarme de la investigación en cualquier momento sin que me afecte en ninguna manera ya que mi participación es de manera voluntaria. Adicionalmente, eximo, deslindo de toda responsabilidad y estoy de acuerdo en no levantar ninguna demanda civil, penal, y reparadora del daño en contra de la Universidad Autónoma de Querétaro, de los investigadores responsables del estudio, ni de ningún empleado, profesores, estudiantes y/o voluntarios de la Institución; esto incluye a mi persona y mi familia. Así mismo se incluye a lo anterior cualquier daño, robo, lesión personal, muerte accidental o cualquier otra situación que pueda resultar de mi participación en el estudio denominado anteriormente (y que posiblemente haya podido ser causada por negligencia de alguna de las partes mencionadas en este párrafo en cualquier momento que haya sucedido).

NOMBRE Y FIRMA
DEL PARTICIPANTE DE ESTUDIO

NOMBRE Y FIRMA
DEL RESPONSABLE DEL PARTICIPANTE DE ESTUDIO

HE LÉIDO CON EXACTITUD O HE SIDO TESTIGO DE LA LECTURA EXACTA DEL DOCUMENTO DE CONSENTIMIENTO INFORMADO PARA EL POTENCIAL PARTICIPANTE Y EL INDIVIDUO HA TENIDO LA OPORTUNIDAD DE HACER PREGUNTAS. CONFIRMO QUE EL INDIVIDUO HA DADO CONSENTIMIENTO LIBREMENTE.

IVÁN JOEL RAMÍREZ ÁNGELES
442 452 22 34
IRAMIREZ16@ALUMNOS.UAQ.MX

DATOS Y FIRMA
DEL INVESTIGADOR

Carta de Confidencialidad



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE INGENIERÍA
CARTA DE CONFIDENCIALIDAD



Santiago de Querétaro, Querétaro., a _____ de _____ del 20_____

N° REGISTRO

Por medio de la presente,

el (la) que suscribe, _____, he leído y comprendido los lineamientos del proyecto denominado **"Detección Y Clasificación De Señales Mieléctricas En El Brazo Mediante El Uso De Algoritmos Basados En Inteligencia Artificial"** y de manera libre, voluntaria y sin coerción alguna, bajo protesta de decir la verdad autorizo a los investigadores de dicho estudio a que la información y datos generados en dicho estudio sean utilizados únicamente con fines de investigación y que estarán a disposición del público en general, institución y/o organización interesada en dichos datos y podrán ser utilizados según sus intereses. Así mismo queda estipulado que mi información personal estará resguardada y protegida bajo la Ley Federal de Protección de Datos Personales en Posesión de los Particulares de los Estados Unidos Mexicanos, en su Capítulo II artículos 11, 12, 19, 21, 24, 36, 44, 47; Capítulo III artículos 63, 64, 65, 66 y Capítulo VII artículos 101, 102, 103, 106, 109.

NOMBRE Y FIRMA
DEL PARTICIPANTE DE ESTUDIO

NOMBRE Y FIRMA
DEL RESPONSABLE DEL PARTICIPANTE DE ESTUDIO

Constancia de Lengua Extranjera

La Mecatrónica en México



DICTÁMEN DE EVALUACIÓN

OFICIO LMEM/20190203-2

Por este medio, el comité editorial de la revista LMEM se les informa a los autores que el trabajo titulado

**Metodología para la Adquisición de Señales
Electromiográficas en el Brazo Utilizando un Lector
de Señales Multicanal**

Con número de registro **LMEM20190114-1**, cuyos autores son

**Ramírez-Ángeles Iván Joel, Razo-López Naela
Berenice, Aceves-Fernández Marco Antonio,
Gorrostieta-Hurtado Efrén**

Ha tenido como dictamen **APROBADO**. Por lo que se requiere revise y apruebe la versión final para publicación, así como el envío del formato de autorización de publicación. Una vez que se cuente con la aprobación y autorización, el artículo será enviado para su publicación.

ATENTAMENTE,
Comité Evaluador de los Artículos de la revista
“La Mecatrónica en México”





Metodología para la Adquisición de Señales Electromiográficas en el Brazo Utilizando un Lector de Señales Multicanal

Ramírez-Ángeles Iván-Joel¹, Razo-López Naela-Berenice¹, Aceves-Fernández Marco-Antonio¹, Gorrostieta-Hurtado Efrén¹

¹Departamento de Ingeniería, Universidad Autónoma de Querétaro. Cerro de las Campanas s/n, Centro Universitario, Las Campanas, CP 76010, Querétaro, México
✉marco.aceves@uaq.mx

Resumen

La electromiografía es el estudio que permite adquirir y entender las señales bioeléctricas generadas por el sistema nervioso hacia los músculos estriados inervados. Estas señales son conocidas como señales electromiográficas (EMG) o señales mioeléctricas y han demostrado de ser de gran utilidad para el entendimiento del cuerpo humano, así como aplicaciones relacionadas con la medicina, domótica o recreación. Actualmente uno de los problemas con las señales EMG es el entendimiento de estas para su uso en aplicaciones mioeléctricas; la finalidad de este artículo es presentar una metodología propia para la adquisición de señales EMG mediante un dispositivo de captura de superficie multicanal para poder presentar las señales con diferentes técnicas de aprendizaje automático (machine learning).

Palabras clave: Electromiografía, Señales EMG, Señales Mioeléctricas, Electromiografía de Superficie, MYO.

Abstract

Electromyography is a study that allows the acquisition and understanding of bioelectric signals originated in the nervous system to skeletal muscles. These signals also known as electromyographic signals (EMG signals) had been proved to be useful for the comprehension of human body helping to a better understanding of human body as well as developing software and tools for medicine, home automation or recreation. This paper aims to introduce an EMG signal acquisition methodology through a surface electromyograph hardware.

Keywords: Electromyography, EMG Signals, Myoelectric Signals, Surface EMG, MYO.

1. Introducción

El movimiento a voluntad de los organismos vertebrados se debe al sistema muscular por el cual estamos constituidos, este sistema está constituido por una variedad de músculos inervados, conocidos como músculos esqueléticos o estriados [1]. La Figura 1 muestra una clasificación de los diferentes tipos de músculos.

Las señales EMG son producidas durante el proceso de contracción y relajación de los músculos estriados, permitiendo así el movimiento. Estas señales son generadas por el intercambio de iones a través de las fibras musculares, la Figura 2 ejemplifica el proceso eléctrico de la generación de la señal hasta el movimiento del músculo.

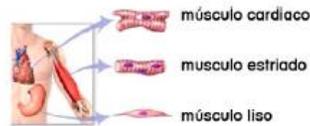


Figura 1. Tipos de músculos en los organismos vertebrados. De derecha a izquierda se muestran el músculo cardíaco, músculo estriado y músculo liso. [2]

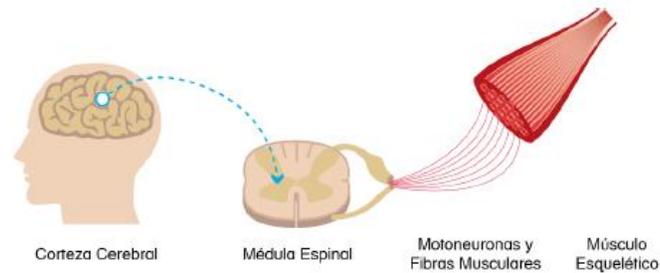


Figura 2. Aunque la señal se origine en las fibras musculares, la orden nace de la corteza cerebral [Imagen Propia].

La electromiografía permite recolectar las señales EMG y presentarlas visualmente (Figura 3). Actualmente existen diferentes técnicas para la extracción de señales, para este caso de estudio se utilizó la electromiografía de superficie (sEMG) donde los electrodos (Figura 4) son posicionados en la superficie de la piel sin generar molestia para la persona.



Figura 3. Señal EMG [Imagen Propia].

Estas mediciones de la señal proporcionan información acerca de los patrones de la actividad muscular, y múltiples aplicaciones de reconocimiento de patrones (*EMG Pattern and Gesture Recognition*) [3] se han desarrollado a la actualidad permitiendo generar aplicaciones para uso médico [4], industrial [5] o recreacional. Actualmente el uso de algoritmos de aprendizaje automático (*Machine Learning*) han facilitado la tarea de clasificación de estas señales [6, 7]. No obstante, para que el algoritmo de ML clasifique correctamente la señal es necesario contar con un conjunto de datos (*dataset*) lo suficientemente amplio y variado para el entrenamiento del algoritmo. El objetivo de este artículo es presentar la metodología correcta para la captura de señales y generar un conjunto de datos de señales para un futuro uso con ML. En la sección 2 se presenta el marco teórico, en la sección 3 la metodología y finalmente en la sección 4 se discutirán los resultados de la metodología.



2. Marco Teórico

La sEMG consiste en colocar electrodos superficiales (Figura 4) en la piel sobre el músculo del cual se desea obtener la información, ya se ha hablado de como la posición de los electrodos afecta la recolección de la señal [8], además se debe de tener en cuenta ciertos factores como la distancia entre el electrodo y la zona de actividad muscular, las propiedades de la piel (por ejemplo, el espesor de la piel y tejido adiposo), las propiedades del electrodo y el amplificador y la calidad del contacto entre la piel y el electrodo.



Figura 4. Electrodo de Superficie [Imagen Propia]

Los músculos registrados pertenecen a la sección del antebrazo y brazo (Figura 5), se enlistan los nombres de los músculos:

- Tríceps
- Supinador
- Extensor Carpo
- Braquiorradial
- Braquial
- Pronador
- Flexor Superficial
- Flexor Profundo

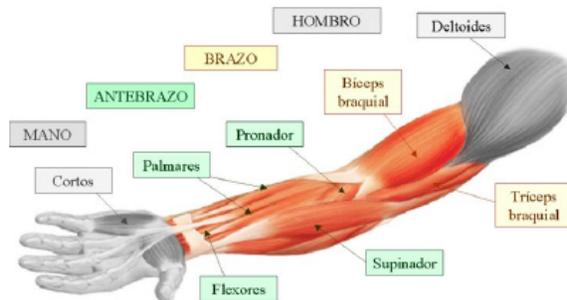


Figura 5. Mapa muscular que muestra la ubicación de los músculos cuyas señales fueron registradas [9].



3. Materiales y Metodología

La metodología que se propone para la adquisición, procesamiento y clasificación de señales se presenta en el siguiente diagrama de bloques (Figura 6). El estudio que se realizó fue basado en las consideraciones éticas planteadas en el tratado de Pautas Éticas Internacionales para la Investigación Biomédica en Seres Humanos [10].

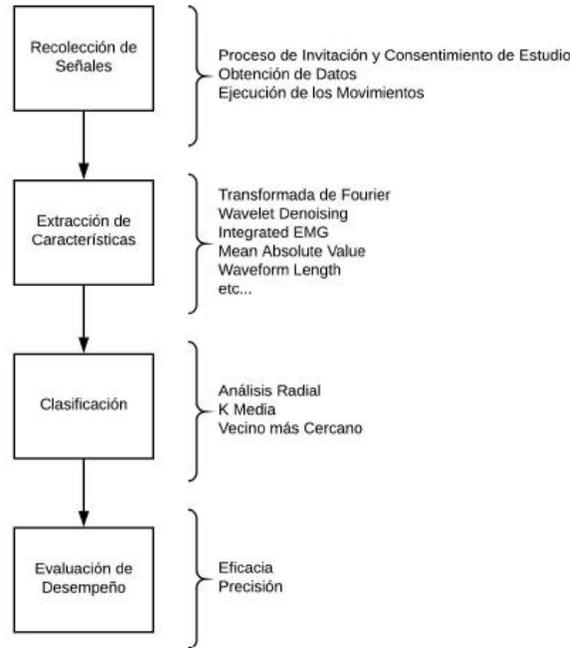


Figura 6. Diagrama de bloques que presenta la metodología y procesos internos a seguir.

3.1 Software y Hardware

Se utilizó el brazalet "MYO Armband" (Figura 7) como hardware recolector de las señales EMG y el software propio de la UAQ "EMGS" (Figura 8) para recolectar las señales y guardarlas en un formato csv. La frecuencia de muestreo del hardware presentado es de 200 Hz.

3.2 Proceso de invitación y consentimiento de estudio.

Se invitará al posible participante, previamente seleccionado del grupo de estudio, a formar parte de la prueba y se le explicará brevemente y de manera clara en que consiste el estudio, lo que se busca realizar con los datos que proporcione y la confidencialidad de estos. Si el voluntario presenta dudas en esta sección, se le brindará la información necesaria para resolverlas. En el caso que el voluntario no desee continuar, se le agradecerá por su tiempo y se finalizará el proceso de invitación, pero si decide aceptar y seguir el proceso, firmará un apartado de consentimiento de estudio y



confidencialidad, posteriormente se le realizará un cuestionario donde deberá contestar las preguntas que se presentan en la Figura 9.



Figura 7. Brazaletes Myo [11].



Figura 8. Software EMGSC que recolecto las señales [Imagen Propia].

EMBARAZO		LACTANCIA		ALTERACIONES NEUROMUSCULARES	
S	N	S	N	S	N
ANTECEDENTES HEMORRÓMICOS					
FARMACOLOGÍA					
ANTECEDENTES PERSONALES PATOLÓGICOS					
CONOCIMIENTO DEL ENTORNO					
TÓPICOS MÁS:					
ACTIVIDAD FÍSICA:					
HOBBIES:					
ALIMENTACIÓN:					
BEBIDAS ENERGIZANTES O CON CAFÉINA:					
HORAS DE SUEÑO:					

Figura 9. Formato de respuestas a las preguntas antes del estudio.



3.3 Descripción de los movimientos registrados.

Los movimientos mostrados a continuación se diseñaron en conjunto con fisioterapeutas con la finalidad de registrar la actividad generada por los músculos del brazo. A continuación, se listan los movimientos e indicaciones para realizar cada movimiento correctamente.

- Posición Inicial (Reposo), en esta postura el participante se mantendrá la palma extendida con los dedos cerrados, sin ejercer demasiada fuerza en los mismos. De esta postura iniciaran los movimientos subsecuentes (Figura 10 a).
- Pronación. Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; se gira la palma de la mano con vista hacia abajo y se regresa a la posición inicial (Figura 10 b).
- Supinación. Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; se gira la palma de la mano con vista hacia arriba y se regresa a la posición inicial (Figura 10 c).
- Extensión. Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; sin mover el codo se lleva la palma de la mano hacia afuera y se regresa a la posición inicial (Figura 10 d).
- Flexión. Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; sin mover el codo se lleva la palma de la mano hacia adentro, con vista hacia el cuerpo y se regresa a la posición inicial (Figura 10 e).
- Desviación Cubital. Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; sin mover el codo se inclina la mano hacia abajo y se regresa a la posición inicial (Figura 10 f).
- Desviación Radial. Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; sin mover el codo se inclina la mano hacia arriba ligeramente y se regresa a la posición inicial (Figura 10 g).
- Pinza Fina. Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; se tocan las yemas de los dedos del pulgar y el índice, se regresan a la posición inicial (Figura 10 h).
- Pinza Gruesa (Cerrar Puño). Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; se hace un puño dejando el pulgar afuera sobre los demás dedos y se regresa a la posición inicial (Figura 10 i).
- Expansión (Abducción de Dedos). Brazo pegado al tronco, codo en flexión de 90°, mano en posición inicial, se procede a hacer el movimiento; se separan todos los dedos y se regresan hacia la posición inicial (Figura 10 j).

Cada movimiento se empezará a realizar cuando se indique y se repetirá 5 veces en un intervalo de 3 segundos, es importante que, si el voluntario muestra un cansancio o incomodidad durante el experimento, este debe pausar permitiendo al voluntario descansar y posteriormente iniciar nuevamente desde el movimiento donde se pausó el ejercicio. El proceso finalizará cuando el voluntario haya ejecutado todos los movimientos cinco veces con cada mano.

Para poder crear una relación entre los electrodos, músculos y movimientos, cada electrodo se número (Figura 11) y se creó un mapa que se muestra en la Tabla 1 y en la Tabla 2, la Tabla 1 muestra que músculo está siendo registrado por cada canal del MYO mientras que la Tabla 2 muestra que músculos y canales son activados ante la ejecución de cada movimiento.

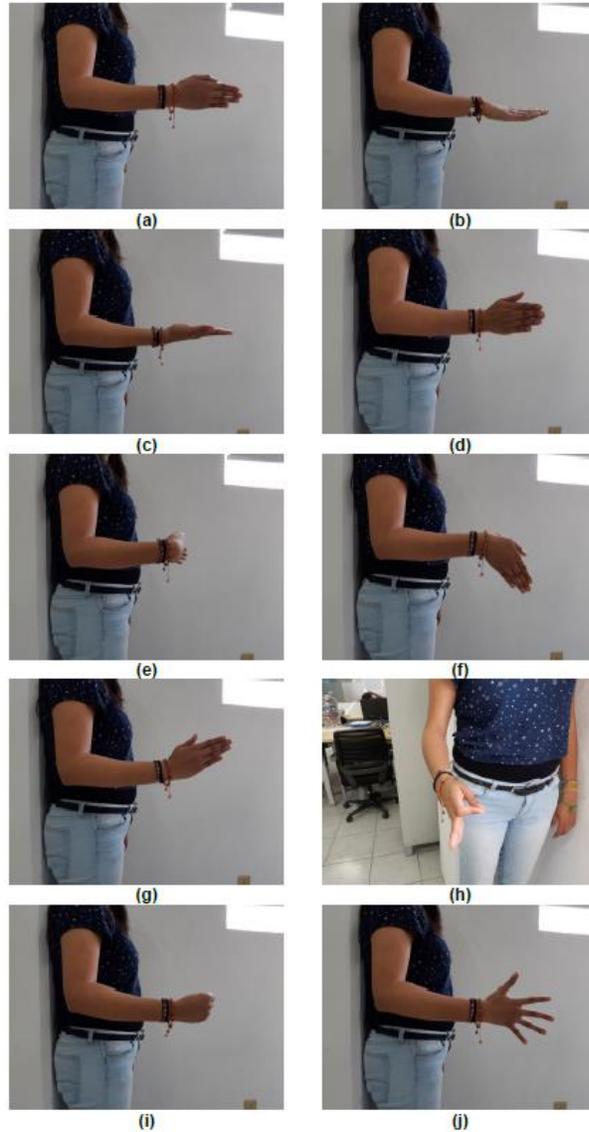


Figura 10. Lista de movimientos, (a) Posición Inicial o Reposo, (b) Pronación, (c) Supinación, (d) Extensión, (e) Flexión, (f) Desviación Cubital, (g) Desviación Radial, (h) Pinza Fina, (i) Pinza Gruesa, (j) Expansión o Abducción de Dedos.

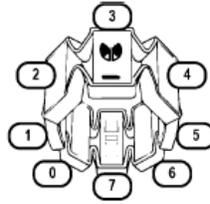


Figura 11. Posición de cada electrodo.

Tabla 1. Relación de Electrodo-Músculo

Electrodo	Músculo
Electrodo 1	Tríceps
Electrodo 2	Extensores, Supinador
Electrodo 3	Epicóndilo, Extensores, Extensor Carpo
Electrodo 4	Extensores, Braquiorradial
Electrodo 5	Braquial, Flexores
Electrodo 6	Flexores, Pronador
Electrodo 7	Epitróclea, Flexores, Flexor Superficial
Electrodo 8	Flexores, Flexor Profundo

Tabla 2. Relación de Electrodo-Movimientos.

Movimientos	Electrodos
Desviación Radial	3, 4 y 5
Desviación Cubital	0, 1 y 2
Flexión de Codo	3
Pinza Gruesa	2 y 4
Pinza Fina	1 y 2
Soltar	0 y 3
Flexión de Muñeca	6, 6, 7 y 0
Extensión de Muñeca	2, 3 y 4

El proceso iniciando desde la preparación del voluntario hasta finalizar, la media de la duración del experimento fue de 15.06 minutos con personal capacitado previamente en el posicionamiento de la pulsera y uso del software. A continuación, en la Figura 12 se muestra el diagrama de flujo del proceso en general para la correcta adquisición de señales.

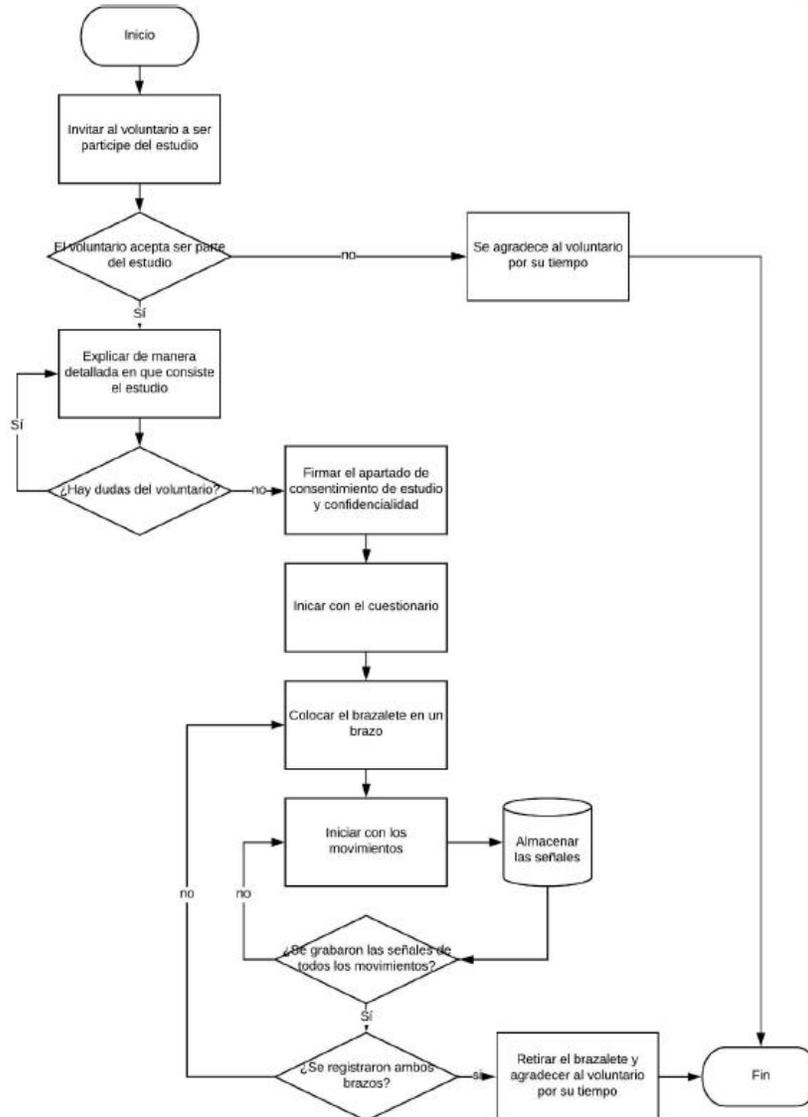


Figura 12. Diagrama de flujo detallando el ciclo para la invitación y recolección de señales EMG.



3.4 Filtrado de las señales

Como resultado del proceso de adquisición de señales se obtuvo una señal en bruto con duración de 16 segundos por cada electrodo (Figura 13), cada una con cinco repeticiones a las cuales llamaremos eventos, por movimiento por brazo dando como resultado 160 señales por persona, no obstante, las señales en bruto necesitaban ser filtradas, a continuación, se muestra una señal de duración de 16 segundos para el movimiento extensión del brazo derecho.

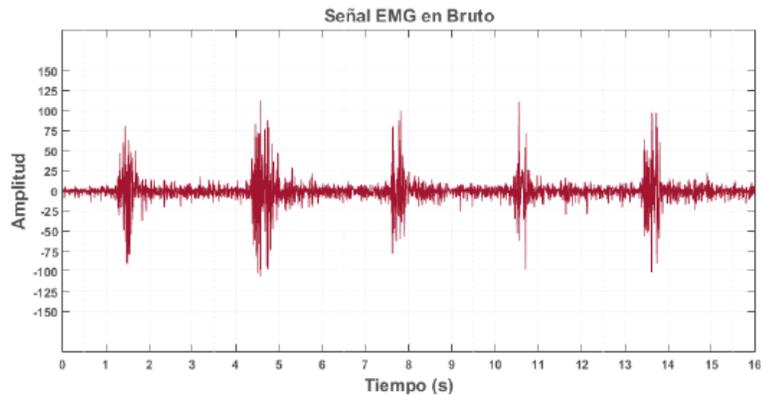


Figura 13. Señal Original adquirida para el movimiento extensión del brazo derecho, se pueden observar los cinco eventos del movimiento.

Antes de poder tratar a la señal con algoritmos de ML es necesario realizar un filtrado para eliminar en su mayoría ruido adquirido durante su adquisición. Por lo que un filtrado de la señal fue necesario antes de poder realizar cualquier tratamiento con las señales. Para el filtrado se decidió trabajar con la transformada wavelet (WT) debido a sus resultados para el filtrado de señales [12-17]. La WT es definida (1) como un análisis multiresolución de una función $f(t)$, el cual descompone la señal original en un conjunto de funciones $W_f(s, \tau)$ que forman los coeficientes wavelets.

$$W_f(s, \tau) = \int f(t) \Psi_{s, \tau}(t) dt \quad (1)$$

Las Wavelets son generadas a partir de la traslación y cambio de escala de una misma función wavelet $\Psi_{s, \tau}(t)$, llamada wavelet madre (2).

$$\Psi_{s, \tau}(t) = \frac{1}{\sqrt{s}} \Psi\left(\frac{t-\tau}{s}\right) \quad (2)$$

Dentro de la WT existen diferentes grupos de familias [18] cuya finalidad es tratar diferentes tipos de señales, en la Tabla 3 se muestra un conjunto de familias y subtipos de wavelets.

Para estas señales, se utilizó el filtro wavelet de la familia db4 a un nivel 10 y el resultado se puede apreciar en la Figura 14 y en la Figura 15 se puede observar una apreciación más a detalle del tercer evento de la misma señal.

La Figura 16 muestra la actividad por cada canal para el movimiento extensión del brazo derecho, se puede observar que la mayor actividad reside solamente en algunos canales en este caso



en el 3, 4, 5 y algo de actividad en el 6, para poder llevar a cabo el calculo de canales significativos por movimiento se calculó IEMG (Integrated EMG) definida en la ecuación 3.

Tabla 3. Familia de Wavelets [18]

Familia de la Wavelet	Subtipo de Wavelet	#
Haar	db1	1
Daubechies	db2-db45	2-45
Coiflet	coif1-coif5	46-50
Morlet	morl	51
Morlet Discreta Compleja	cmor	52-147
Meyer Discreta	dmey	148
Meyer	meyr	149
Sombrero Mexicano	mexh	150
Shannon	shan	151-200
"Frequency B-spline"	fbsp	201-260
Gausiana	gaus	261-267
Gausiana Biortogonal Compleja	cgaus	268-275
Biortogonal	bior	276-290
Biortogonal Inversa	rbio	291-305
Symlet	sym	306-324

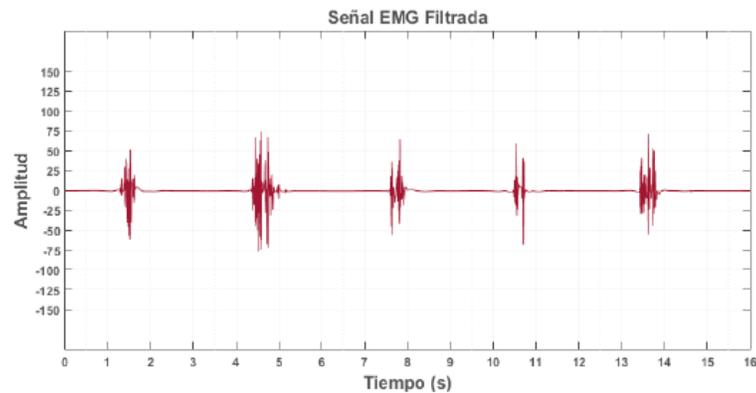


Figura 14. Comparación de la señal en bruto adquirida contra la misma señal filtrada con wavelet db4.

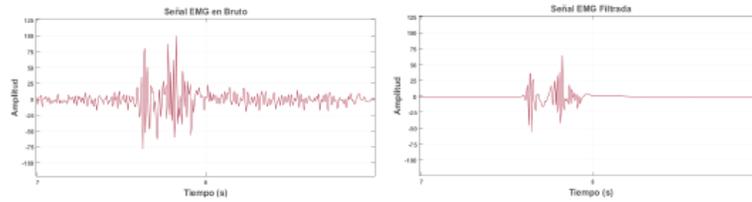


Figura 15. Comparación del tercer evento de la señal EMG en bruto y filtrada

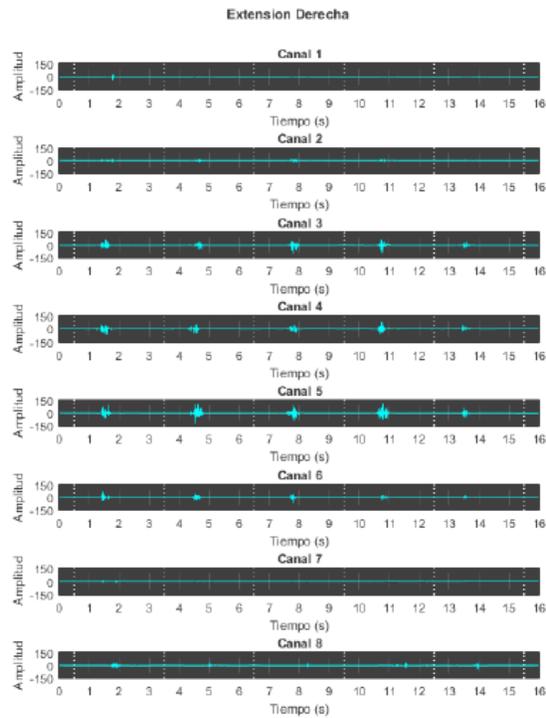


Figura 16. Comparación de actividad por canal para extensión derecha.

IEMG Se usa normalmente como un índice de detección de inicio en el reconocimiento EMG sin patrones y en aplicaciones clínicas [17].

$$IEMG = \sum_{i=1}^N |x_i|. \quad (3)$$



donde x_i representa la señal EMG en un segmento i y N denota la longitud de la señal EMG. Las Figura 17 Figura 18 muestran una comparativa de los canales utilizando IEMG para cada movimiento.

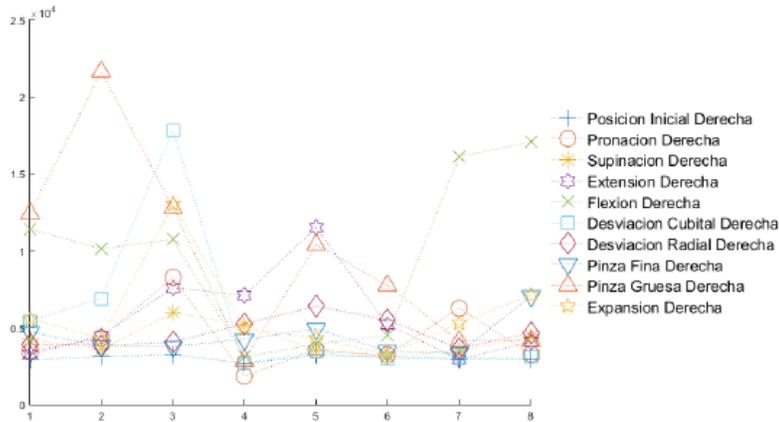


Figura 17. Canales más significativos por movimientos del brazo derecho.

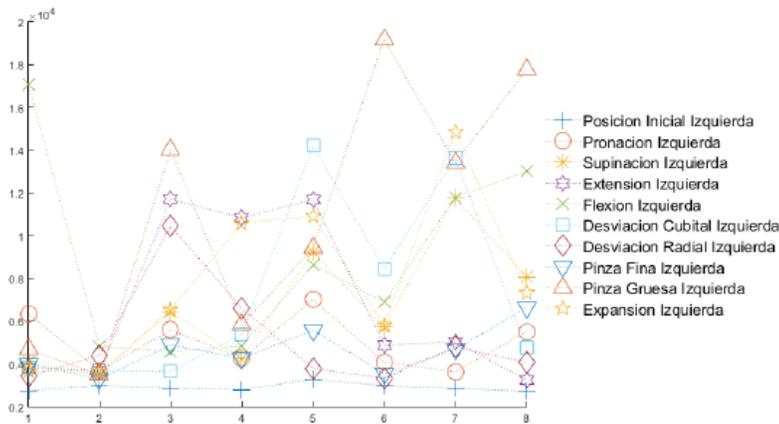


Figura 18. Canales más significativos por movimientos del brazo izquierdo.

4. Discusión de Resultados

El presente trabajo se encargo de presentar el origen de una señal EMG, los tipos de electrodos para poder capturar estas señales, de presentar la metodología para una correcta captura de las señales y finalmente de un filtro adecuado para tratar con este tipo de señales bioeléctricas, así como de explicar



el calculó IEMG para diferenciar los canales más significativos por canal. Como trabajo futuro se pretende continuar con la investigación utilizando un banco de señales capturadas para posteriormente utilizar un algoritmo de ML que clasifique por movimientos las señales y generar una interfaz mioeléctrica, el proceso se muestra en el siguiente diagrama de bloques (Figura 19).

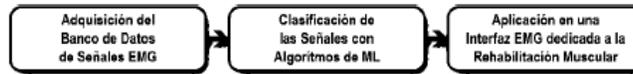


Figura 19. Diagrama de bloques con el proceso para generar una interfaz mioeléctrica.

La complejidad reside en la clasificación de las señales, primero las señales bioeléctricas suelen variar entre personas razón por la cual no se recomienda utilizar el entrenamiento de una sola persona para generar un modelo de clasificación, poder generalizar la información, en futuro se busca generar un banco de datos lo suficientemente robusto para que un algoritmo de clasificación (*Ensemble Empirical Mode Decomposition* [19], *Support Vector Machine* [18], *ELM Classifier* [20]).

5. Conclusiones

El presente artículo se encargó de presentar las señales EMG, y ejemplificar algunas de sus diferentes usos en aplicaciones clínicas y recreacionales; de introducir un protocolo propio basado en consideraciones éticas internacionales para la correcta adquisición de señales EMG de diferentes participantes así como dar a conocer las diferentes familias de wavelets y demostrar que la wavelet db4 ofrece buenos resultados para la filtración de ruido de una señal EMG de 200 Hz tomando en cuenta el teorema de muestreo de Nyquist-Shannon, dado que la frecuencia de una señal EMG del músculo del brazo oscila entre los 50 Hz y 150 Hz. Finalmente se muestran los resultados de la filtración de las señales, y se ejecuta una comparativa de canales, utilizando IEMG como valor para determinar que aquellos con más información para los diferentes movimientos ejecutados por ambos brazos.

La motivación principal de este trabajo es en un futuro aportar un trabajo que mediante técnicas de aprendizaje automático permitan ofrecer un apoyo a fisioterapeutas para la correcta y rápida rehabilitación de sus pacientes. Se exponen las herramientas y técnicas existentes para el muestreo de las señales EMG y el software y hardware adecuado para la correcta captura de la señal. Y se busca que este artículo sirva como base para futuro trabajo para trabajos utilizando técnicas de Inteligencia Artificial que permitan un mejor entendimiento de las señales EMG.

Referencias

- [1] Costanzo, L. S. (2011). *Fisiología Celular*, Elsevier.
- [2] Marieb, E. N., & Hoehn, K. (2007). *Human anatomy & physiology*. Pearson Education.
- [3] Young, A. J., Smith, L. H., Rouse, E. J., & Hargrove, L. J. (2013). Classification of simultaneous movements using surface EMG pattern recognition. *IEEE Transactions on Biomedical Engineering*, 60(5), 1250–1258. <https://doi.org/10.1109/TBME.2012.2232293>
- [4] Subasi, A. (2013). Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders. *Computers in biology and medicine*, 43(5), 576-586.
- [5] Meeker, C., & Ciocarlie, M. (2018). EMG-Controlled Hand Teleoperation Using a Continuous Teleoperation Subspace. *arXiv preprint arXiv:1809.09730*.
- [6] Yousefi, J., & Hamilton-Wright, A. (2014). Characterizing EMG data using machine-learning tools. *Computers in Biology and Medicine*, 51, 1–13. <https://doi.org/10.1016/j.compbiomed.2014.04.018>
- [7] Subasi, A. (2012). Classification of EMG signals using combined features and soft computing techniques. *Applied Soft Computing Journal*, 12(8), 2188–2198. <https://doi.org/10.1016/j.asoc.2012.03.035>



- [8] Rainoldi, A., Melchiorri, G., & Caruso, I. (2004). A method for positioning electrodes during surface EMG recordings in lower limb muscles. *Journal of Neuroscience Methods*, 134(1), 37–43. <https://doi.org/10.1016/j.jneumeth.2003.10.014>
- [9] Mapa Muscular por Anatomía muscular. ¿Qué es?, fisiología y mucho más. (2018). [online] Disponible en: <http://tucuerpohumano.com/c-sistema-muscular/anatomia-muscular/> [Último acceso 24 ago. 2018].
- [10] Favalaro, A. D. R. (2008). Pautas éticas internacionales para la investigación biomédica en seres humanos. *Index Infectológico*, 13.
- [11] Myo (2016). Disponible en: <https://www.myo.com/techspecs>.
- [12] Chen, G. (2014). Automatic EEG seizure detection using dual-tree complex wavelet-Fourier features. *Expert Systems with Applications*, 41(5), 2391–2394. <https://doi.org/10.1016/j.eswa.2013.09.037>
- [13] Hussain, M. S., & Mamun, M. (2012). Wavelet denoising and Surface Electromyography analysis. *Research Journal of Applied Sciences, Engineering and Technology*, 4(15), 2372–2374.
- [14] Phinyomark, A., Limsakul, C., & Phukpattaranont, P. (2009). An optimal wavelet function based on wavelet denoising for multifunction myoelectric control. 2009 6th International Conference on Electrical Engineering/Electronics, [15] Computer, Telecommunications and Information Technology, 1098–1101. <https://doi.org/10.1109/ECTICON.2009.5137236>
- [16] Gokgoz, E., & Subasi, A. (2015). Comparison of decision tree algorithms for EMG signal classification using DWT. *Biomedical Signal Processing and Control*, 18, 138–144. <https://doi.org/10.1016/j.bspc.2014.12.005>
- [17] Huang, H.P., & Chen, C.Y. (1999). Development of a myoelectric discrimination system for a multi-degree prosthetic hand. In *Proceedings of IEEE International Conference on Robotics and Automation* (Vol. 3, pp. 2392–2397).
- [18] Subasi, A. (2013). Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders. *Computers in Biology and Medicine*, 43(5), 576–586. <https://doi.org/10.1016/j.compbiomed.2013.01.020>
- [19] Naik, G. R., Selvan, S. E., & Nguyen, H. T. (2016). Single-channel EMG classification with ensemble-empirical-mode-decomposition-based ICA for diagnosing neuromuscular disorders. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 24(7), 734–743. <https://doi.org/10.1109/TNSRE.2015.2454503>
- [20] Mishra, V. K., Bajaj, V., & Kumar, A. (2016). Classification of normal, ALS, and myopathy EMG signals using ELM classifier. *Proceeding of IEEE - 2nd International Conference on Advances in Electrical, Electronics, Information, Communication and Bio-Informatics, IEEE - AEEICB 2016*, 455–459. <https://doi.org/10.1109/AEEICB.2016.7538330>