

# **METODOLOGÍA BASADA EN ENTRENAMIENTO AUTOMÁTICO PARA EL RECONOCIMIENTO DEL MOVIMIENTO INDIVIDUAL DE LOS DEDOS DE LA MANO USANDO ANÁLISIS DE SEÑALES ELECTROMIOGRÁFICAS DE SUPERFICIE**

**Laura Stella Vega Escobar**

**Maestría**  
en Automatización y Control Industrial

Directores: M.Sc. Andrés Eduardo Castro Ospina  
PhD. (c) Juan Sebastián Botero Valencia



**Institución Universitaria**

*Instituto Tecnológico Metropolitano*  
*Facultad de Ingenierías*  
Medellín, 2018

# AGRADECIMIENTOS

Agradezco a mis **padres** y **hermanas** por el acompañamiento y el apoyo para culminar esta etapa profesional de mi vida. A mis directores **Juan Sebastián Botero Valencia** y **Andrés Eduardo Castro** por el apoyo brindado, motivación, tiempo y orientación para desarrollar esta tesis.

También quiero agradecer a **Cristian Alzate Anzola** y **Joao Mesa Pérez** por ayudarme al desarrollo del prototipo de la adquisición de los datos. Agradezco a todas las personas que me brindaron un espacio de su tiempo para la adquisición de los datos de esta tesis. Al **Laborario de Máquinas Inteligentes y Reconocimiento de Patrones** y al **Laboratorio de Sistemas de Control y Robótica** por el suministro de equipos y sensores necesarios para desarrollar esta tesis.

# RESUMEN

El reconocimiento del movimiento de los dedos de la mano es un área de investigación activa en la aplicación de interfaces músculo Computador (muCI) en la que la persona realiza un gesto (combinación de movimientos de los dedos) y una máquina reconoce el movimiento real. Al reconocer los movimientos individuales de los dedos de la mano se puede simular la motricidad fina que proporcionen un control individual de los dedos. En esta tesis se presenta una metodología para el reconocimiento del movimiento individual de los dedos de la mano, basado en la estimación de características de las señales electromiográficas superficiales adquiridas en el antebrazo. Se adquirió un conjunto de datos con 54 sujetos y ocho señales (canales) por sujeto mediante un sensor inalámbrico, luego, se hizo una etiquetación automática de este conjunto para el posterior reconocimiento y se analizaron las características extraídas en tres tipos de dominios, tales como, el tiempo, la frecuencia y tiempo-frecuencia, formando un conjunto de 720 características. Además, para la estimación de características en el dominio de tiempo-frecuencia se realizó un experimento con el fin de encontrar los parámetros más representativos en la descomposición con la transformada Wavelet discreta y así, generar un espacio de representación apropiado. Se seleccionó un subconjunto de características y se entrenó con los clasificadores Máquinas de Vectores de Soporte (SVM), análisis discriminante lineal (LDA) y vecinos más cercanos ( $k$ -NN) con una validación cruzada de 10 iteraciones para evitar el sobreajuste. Se logra una exactitud superior al 95% con el clasificador SVM y 98% con LDA, no obstante, el  $k$ -NN no obtuvo un buen rendimiento en términos de la media geométrica debido a que requiere de una sintonización de los  $k$ -vecinos, lo que implica que la metodología propuesta facilita el reconocimiento del movimiento individual de los dedos utilizando el clasificador LDA.

**Keywords:** Adquisición inalámbrica, estimación de características, reconocimiento de los movimientos de los dedos, electromiografía superficial, clasificación.

# ÍNDICE GENERAL

<b>Agradecimientos</b>	<b>ii</b>
<b>Resumen</b>	<b>iii</b>
<b>Índice General</b>	<b>v</b>
<b>Índice de figuras</b>	<b>vi</b>
<b>Índice de tablas</b>	<b>vii</b>
<b>Introducción</b>	<b>1</b>
Hipótesis . . . . .	2
Objetivos . . . . .	3
General . . . . .	3
Específicos . . . . .	3
Estructura . . . . .	3
Contribución. . . . .	3
Referencias. . . . .	3
<b>1 Conceptos preliminares</b>	<b>7</b>
1.1 Anatomía de la mano . . . . .	8
1.1.1 Fisiología de la Mano . . . . .	8
1.1.2 Huesos y Articulaciones de la Mano . . . . .	8
1.1.3 Dedos de la Mano . . . . .	8
1.1.4 Flexión y Extensión de los dedos de la Mano . . . . .	8
1.1.5 Músculos del antebrazo . . . . .	8
1.1.6 Electromiografía (EMG) . . . . .	9
1.1.7 Electromiografía Superficial (sEMG) . . . . .	9
1.1.8 Potenciales de Unidad Motora . . . . .	9
1.2 Instrumentos . . . . .	10
1.2.1 Brazaletes de Electrodo . . . . .	10
1.2.2 Sensores flexibles . . . . .	10
1.3 Descomposición de Modo Empírico (EMD). . . . .	11
1.4 Estimación de características . . . . .	11
1.4.1 Características en el dominio del tiempo. . . . .	11
1.4.2 Características en el dominio de Frecuencia . . . . .	13
1.4.3 Características en el dominio de Tiempo-Frecuencia . . . . .	15
1.5 Reducción de dimensión y Clasificación . . . . .	15
1.5.1 Selección Secuencial hacia Adelante (SFS) . . . . .	15
1.5.2 Análisis de Componentes Principales (PCA) . . . . .	15
1.5.3 $k$ - vecinos más cercanos ( $k$ -NN) . . . . .	15
1.5.4 Máquinas de Vectores de Soporte (SVM) . . . . .	15
1.5.5 Análisis discriminante lineal (LDA) . . . . .	16
1.5.6 Medidas de rendimiento de los clasificadores . . . . .	16
Referencias. . . . .	16

---

<b>2 Adquisición de datos</b>	<b>19</b>
2.1 Prototipo de Adquisición . . . . .	19
2.2 Protocolo experimental . . . . .	20
2.3 Adquisición base de datos . . . . .	21
2.4 Etiquetado Automático . . . . .	22
Referencias. . . . .	30
<b>3 Reconocimiento del movimiento</b>	<b>31</b>
3.1 Generación de un espacio de representación . . . . .	31
3.1.1 Selección de parámetros para la Transformada de Wavelet. . . . .	32
3.2 Reducción de Características . . . . .	35
3.3 Clasificación . . . . .	35
Referencias. . . . .	48
<b>4 Conclusiones y trabajo futuro</b>	<b>50</b>

# ÍNDICE DE FIGURAS

1.1	Huesos y Articulaciones de la mano. Adaptado de [2] . . . . .	8
1.2	Músculos del antebrazo. Tomado de [7] . . . . .	9
2.1	Prototipo de Adquisición . . . . .	21
2.2	Diagrama de las etapas del etiquetado propuesto . . . . .	22
2.3	Señal original con las cinco repeticiones claramente visibles . . . . .	23
2.4	Señales originales que presentan activaciones involuntarias . . . . .	24
2.5	Señales originales donde se presentan diferentes mínimos . . . . .	25
2.6	Señales originales donde se presentan diferentes corrimientos de línea base . . . . .	27
2.7	Proceso de identificación de la actividad motora voluntaria . . . . .	28
2.8	Señal sEMG etiquetada con la metodología propuesta . . . . .	29
3.1	Comparación con el conjunto de datos con características estimadas a partir de los coeficientes de las familias Wavelet vs desempeño (media geométrica) con diferentes clasificadores y niveles de descomposición del 3 al 8 . . . . .	33
3.2	Comparación con el conjunto de datos reducido con PCA de las familias Wavelet vs desempeño con diferentes clasificadores y niveles de descomposición del 3 al 8 . . . . .	34
3.3	Comparación con el conjunto de datos reducido con SFS de las familias Wavelet vs desempeño con diferentes clasificadores y niveles de descomposición del 3 al 8 . . . . .	35
3.4	Experimentación con los conjuntos de características para evaluar el desempeño para el reconocimiento del movimiento individual de los dedos . . . . .	36
3.5	Comparación con el conjunto de características XT y el clasificador $k$ -NN . . . . .	37
3.6	Comparación con el conjunto de características XF y el clasificador $k$ -NN . . . . .	38
3.7	Comparación con el conjunto de características XTF y el clasificador $k$ -NN . . . . .	39
3.8	Comparación con todo el conjunto de características XT+XF+XTF y el clasificador $k$ -NN . . . . .	40
3.9	Comparación con el conjunto de características XT y el clasificador LDA y SVM . . . . .	41
3.10	Comparación con el conjunto de características XF y el clasificador LDA y SVM . . . . .	42
3.11	Comparación con el conjunto de características XTF y el clasificador LDA y SVM . . . . .	43
3.12	Comparación con el conjunto de combinaciones de características y el clasificador LDA . . . . .	44
3.13	Comparación con el conjunto de combinaciones de características y el clasificador SVM . . . . .	45
3.14	Desempeño con los clasificadores SVM y LDA con el conjunto de características XT+XF+XTF reducidas con PCA . . . . .	46
3.15	Desempeño con los clasificadores SVM y LDA con el conjunto de características XT+XF+XTF reducidas con SFS . . . . .	47

# ÍNDICE DE TABLAS

1.1	Especificación Técnica MYO Armband . . . . .	10
1.2	Datos Técnicos Sensor Flexible 56 mm . . . . .	11
3.1	Características estimadas a partir de señales sEMG. Para más información, ver [3] . . . . .	32
3.2	Resultados principales(con el conjunto de características XT+XF+XTE, con $k=1$ y con la medida de desempeño media geométrica) para el reconocimiento del movimiento individual de los dedos de la mano . . . . .	41

# INTRODUCCIÓN

El reconocimiento de los movimientos de los dedos de la mano es un campo de investigación de la ciencia computacional y el desarrollo de interfaces hombre máquina (HMI). El objetivo de este campo es interpretar los gestos de las manos (combinaciones de movimientos de los dedos) con el fin de permitir una comunicación entre el hombre y la máquina, e implementar nuevas estrategias de control, desarrollar aplicaciones en áreas de biomédica [1], medicina [2], robótica [3–5], lenguaje de señas [6], entre otras.

Ante la creciente demanda de las HMI se ha desarrollado una aplicación que integra una comunicación directa con los músculos conocida como interfaz músculo computador (muCI), término usado por primera vez en 2008 por los investigadores Saponas et al [7, 8]. Las muCI utilizan señales de electromiografía superficial (sEMG) obtenidas a través de sensores que miden la actividad eléctrica generada en el músculo durante su contracción, para después traducirse en instrucciones de computadora.

Las sEMG, son muy utilizadas en diferentes investigaciones [9–17], debido a que estos sensores no son invasivos y no producen incomodidad a los sujetos en comparación a los sensores internos que se basan en agujas introducidas en la piel. Novedosos sensores interactivos y portables se han propuesto para la medición de la señal eléctrica muscular, tal como el dispositivo Myo Armband<sup>®</sup> fabricado por Thalmic Labs, este brazalete contiene 8 electrodos, un giroscopio, un acelerómetro y un magnetómetro para realizar reconocimiento de gestos de la mano [18]. Este dispositivo no requiere de un uso excesivo de cables y conexiones para la medición de las señales debido a que es inalámbrico, y los electrodos son de acero inoxidable permitiendo tener una vida útil mayor con respecto a los electrodos superficiales tradicionales, además, no necesita de un amplio estudio para la localización de electrodos en los sujetos.

Algunos investigadores, han usado el dispositivo Myo Armband<sup>®</sup> para la adquisición de señales de electromiografía como Pomboza-Junez Gonzalo y Holgado-Terriza Juan A., quienes emplearon el brazalete Myo Armband<sup>®</sup> para detectar gestos de la mano, además de la rotación y orientación de los movimientos realizados por el sujeto [19]. De forma similar hicieron en el Instituto Nacional de Ciencia y Tecnología Industrial Avanzada, los cuales presentaron una metodología para reconocer gestos utilizando el Myo Armband<sup>®</sup> [20]. También se ha realizado un modelo para el reconocimiento de gestos manuales en tiempo real empleando el Myo Armband<sup>®</sup> y aprendizaje de máquinas [21].

Por otra parte, Simone Benatti et al. combinaron el dispositivo Myo Armband<sup>®</sup> con los sensores Ottobock para realizar el reconocimiento de 7 gestos de la mano de 4 sujetos en tiempo real. Las señales fueron clasificadas mediante Máquinas de Vectores de Soporte obteniendo un rendimiento del 90% para el reconocimiento de gestos en tiempo real [22]. Al igual en [23], propusieron otro enfoque de combinación de un guante compuesto por sensores flexibles y el brazalete Myo Armband<sup>®</sup>, para identificar el parámetro LOVETT de las personas que sufrieron un accidente cerebrovascular con Etil glucurónido (ETG), permitiendo a un médico controlar la rehabilitación del paciente simplemente mirando los datos del registro del ETG.

Se han generado diferentes bases de datos con el propósito de reconocer movimientos y gestos de las manos, utilizando sensores que permiten registrar las señales de electromiografía, tal como se mencionó anteriormente. Entre las bases de datos encontradas están CapgMyo [24], Myo Dataset [25], csl-hdemg [26] y Ninapro [27], siendo esta última la más utilizada en la literatura [28–33]. Estas bases de datos requieren de una etiquetación para desarrollar posteriores etapas de aprendizaje automático y desarrollar modelos de aprendizaje supervisado. Usualmente, las bases de datos son etiquetadas a partir de la reacción a estímulos visuales a medida que se adquiere cada registro o se etiquetan manualmente por un experto. Sin embargo, algunos de estos métodos de etiquetación pueden presentar errores, por ejemplo, los movimientos realizados por el sujeto pueden ser diferentes a los sugeridos por el estímulo visual dado, lo que genera la necesidad de realizar un proceso de re-etiquetado de los datos y además conseguir una persona experta requiere de tiempo y costos altos.

Diferentes metodologías se han implementado para la etapa de aprendizaje automático de gestos y movimientos de los dedos de la mano, entre ellos, para la etapa de estimación de características se han usado en la literatura características en el tiempo como Valor Absoluto Medio (MAV), Longitud de Forma de Onda (WL),



Cruces por Cero (ZC), Cambios de Signo de Pendiente (SSC), Amplitud de Willison (WAMP), entre otros [15, 34–36], en frecuencia se ha implementado la Frecuencia Media (FMN), Frecuencia Mediana (FDM), Modificada Frecuencia Media (MFMN), Tasa de Frecuencia (FR), entre otros [37, 38]. Finalmente, en tiempo-frecuencia, la Transformada de Fourier de tiempo corto (STFT) y la Transformada de Wavelet Discreta (DWT) son las más utilizadas [11, 39, 40]. En el estado del arte para la estimación de características con DWT se han empleado diferentes Wavelet madre, entre ellas están: Daubechies de orden 4, 5, 7 y 8 (db4, db5, db7, db8), coiflet de orden 5 (coif5), symlets de orden 5 (sym5), biorthogonal de orden 4.4 (bior4.4), reverse biorthogonal de orden 2.2 (rbio2.2), entre otras, y con niveles de descomposición 3, 6, 7, 8, entre otros [11, 27, 41, 42]. Lo anterior quiere decir que no hay un parámetro estándar para utilizar la DWT en esta aplicación. Por otro lado, con todas las características obtenidas se hace necesario realizar una reducción de dimensión para identificar y remover las características irrelevantes, mejorar el rendimiento computacional y reducir la complejidad, para esto se han empleado técnicas de extracción de características como análisis de componentes principales (PCA) y el análisis de componentes independientes (ICA), y los métodos de selección de características como selección secuencial hacia adelante, selección secuencial hacia atrás, entre otros [43].

Las técnicas de aprendizaje más utilizadas en el campo del procesamiento de señales sEMG son de aprendizaje supervisado, debido a que se tiene la ventaja de las etiquetas preestablecidas para entrenar un clasificador. Los más mencionados y seleccionados en la literatura son los  $k$  vecinos más cercanos ( $k$ -NN) [15, 44–46], Máquinas de Vectores de Soporte (SVM) [47–49] y aprendizaje profundo [50–52].

En consecuencia a lo mencionado anteriormente, las técnicas de estimación de características y los clasificadores utilizados por los investigadores se han aplicado a las bases de datos de reconocimiento de gestos y movimientos de los dedos de la mano, en las que la persona realiza el gesto o un movimiento siguiendo un estímulo visual, permitiendo etiquetar la base de datos para la posterior clasificación, sin embargo, esta etiquetación puede presentar errores, obligando a llevar a cabo un proceso de re-etiquetado de datos, además, en la etapa de generación de un espacio de representación a partir de características en el dominio de tiempo-frecuencia con la DWT, se requiere de un análisis previo para identificar cuales son los parámetros (Wavelet madre, orden y niveles de descomposición) que permitan obtener un buen desempeño con el clasificador debido a la alta variedad de estos parámetros encontrados en la literatura.

Los gestos son una combinación de movimientos de los dedos, por lo tanto, reconocer el movimiento individual de los dedos de la mano, permitirá reconocer diferentes gestos. Según lo anterior, en esta tesis se propone una metodología en entrenamiento automático que se enfocará en el reconocimiento del movimiento individual de los dedos de la mano utilizando señales sEMG mediante una adquisición inalámbrica, un etiquetado automático de la base de datos para evitar una re-etiquetación, una etapa de estimación de características utilizando características en los dominios del tiempo, frecuencia y tiempo-frecuencia. En esta última se hizo un análisis exhaustivo con varias Wavelet madre y diferentes niveles de descomposición para encontrar la combinación que mejor desempeño brinde en términos de discriminación y, finalmente, una etapa de clasificación usando SVM, LDA, y  $k$ -NN. Los resultados obtenidos muestran que la metodología propuesta facilita el reconocimiento del movimiento individual de los dedos, utilizando como Wavelet madre la familia Daubechies de orden 8 (db8) y 8 niveles de descomposición como parámetros de la DWT, y con un rendimiento moderado para  $k$ -NN ya que logra una baja sensibilidad, pero por otro lado, alcanza un alto rendimiento para LDA y SVM en términos de cuatro medidas de rendimiento superiores al 95% para reconocer los movimientos individuales de los dedos de la mano.

## PREGUNTA DE INVESTIGACIÓN E HIPÓTESIS

¿Se puede reconocer el movimiento individual de los dedos de la mano sin depender de una ubicación específica de canales, usando análisis de señales electromiográficas de superficie basándose en técnicas de entrenamiento automático y descomposición?

Se puede reconocer el movimiento individual de los dedos de la mano mediante una adquisición inalámbrica de señales electromiográficas de superficie; analizando y procesando la señal, estimando características de los patrones relevantes de la señal a partir de técnicas de descomposición, segmentación y caracterización. Estas características estimadas permiten la posterior clasificación de la señal usando diferentes técnicas para discriminar los movimientos individuales de los dedos de la mano.

## OBJETIVOS

### GENERAL

Proponer una metodología basada en entrenamiento automático para el reconocimiento del movimiento individual de los dedos de la mano, a partir de la adquisición y el análisis de señales electromiográficas de superficie.

### ESPECÍFICOS

- Establecer un protocolo experimental para la adquisición de señales electromiográficas superficiales del antebrazo usando un brazalete de electrodos con el fin de analizarlas para encontrar la mayor correspondencia entre los canales y los movimientos de los dedos de la mano.
- Generar un espacio de representación del movimiento individual de los dedos de la mano, derivado del análisis de señales electromiográficas de superficie.
- Clasificar el movimiento individual de los dedos de la mano mediante técnicas de entrenamiento automático de forma que se reduzca el error de reconocimiento en cada movimiento.

## ESTRUCTURA

El cuerpo de esta tesis está constituida por 5 capítulos, en el Capítulo 1 presenta las definiciones y conceptos fundamentales para el desarrollo de la presente tesis; en el Capítulo 2 se explica el protocolo propuesto para la adquisición de los datos utilizando un brazalete de electrodos y una etiquetación automática usando sensores flexibles; el Capítulo 3 corresponde a la generación de un espacio de representación y clasificación para la discriminación del movimiento individual de los dedos de la mano en términos de desempeño-error y por último, en el Capítulo 4 se exponen las conclusiones alcanzadas, basándose en los resultados que se obtuvieron al analizar y desarrollar esta tesis, además de los proyectos futuros generados a partir de éstos.

## CONTRIBUCIONES

- Artículo: Vega-Escobar, L. S., Castro-Ospina, A. E., Duque-Muñoz, L. (2018, September). *Individual Finger Movement Recognition Based on sEMG and Classification Techniques*. In International Workshop on Artificial Intelligence and Pattern Recognition, Lecture Notes in Computer Science book series (LNCS, volume 11047), pp. 113-121. Springer, Cham. [https://doi.org/10.1007/978-3-030-01132-1\\_13](https://doi.org/10.1007/978-3-030-01132-1_13)

## REFERENCIAS

- [1] J. E. Muñoz-Cardona, O. A. Henao-Gallo, and J. F. López-Herrera, "Sistema de Rehabilitación basado en el Uso de Análisis Biomecánico y Videojuegos mediante el Sensor Kinect," *TecnoLógicas*, p. 43, nov 2013.
- [2] Y. Xu, D. Zhang, Y. Wang, J. Feng, and W. Xu, "Two ways to improve myoelectric control for a transhumeral amputee after targeted muscle reinnervation: a case study," *J. Neuroeng. Rehabil.*, vol. 15, no. 1, p. 37, 2018.
- [3] N. Feng, Q. Shi, H. Wang, J. Gong, C. Liu, and Z. Lu, "A soft robotic hand: design, analysis, sEMG control, and experiment," *Int. J. Adv. Manuf. Technol.*, mar 2018.
- [4] J. G. Hoyos-Gutiérrez, C. A. Peña-Solórzano, C. L. Garzón-Castro, F. A. Prieto-Ortiz, and J. G. Ayala-Garzón, "Towards tool handling by a nao robot using programming by demonstration," *TecnoLógicas*, vol. 17, no. 33, pp. 65–76, 2014.
- [5] L. F. Escobar-Dávila, O. D. Montoya-Giraldo, and D. Giraldo-Buitrago, "Control global del péndulo de Furuta empleando redes neuronales artificiales y realimentación de variables de estado," *TecnoLógicas*, pp. 71–94, 2013.
- [6] D. Hirafuji Neiva and C. Zanchettin, "Gesture recognition: A review focusing on sign language in a mobile context," *Expert Syst. Appl.*, vol. 103, pp. 159–183, 2018.

- [7] A. Chowdhury, R. Ramadas, and S. Karmakar, "Muscle computer interface: a review," in *ICoRD'13*. Springer, 2013, pp. 411–421.
- [8] T. S. Saponas, D. S. Tan, D. Morris, and R. Balakrishnan, "Demonstrating the feasibility of using forearm electromyography for muscle-computer interfaces," in *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. ACM, 2008, pp. 515–524.
- [9] M. Haris, P. Chakraborty, and B. V. Rao, "EMG Signal Based Finger Movement Recognition for Prosthetic Hand Control," in *2015 Int. Conf. Commun. Control Intell. Syst. Communication, Control and Intelligent Systems (CCIS)*, 2015, 2015, p. 5.
- [10] Y. Zhou, G. Jiang, and Y. Lin, "A novel finger and hand pose estimation technique for real-time hand gesture recognition," *Pattern Recognit.*, vol. 49, pp. 102–114, 2016.
- [11] F. Duan, L. Dai, W. Chang, Z. Chen, C. Zhu, and W. Li, "sEMG-Based Identification of Hand Motion Commands Using Wavelet Neural Network Combined With Discrete Wavelet Transform," *IEEE Trans. Ind. Electron.*, vol. 63, no. 3, pp. 1923–1934, mar 2016.
- [12] C. P. Robinson, B. Li, Q. Meng, and M. T. Pain, "Pattern Classification of Hand Movements using Time Domain Features of Electromyography," in *Proc. 4th Int. Conf. Mov. Comput. - MOCO '17*. New York, New York, USA: ACM Press, 2017, pp. 1–6.
- [13] N. Jarrasse, C. Nicol, A. Touillet, F. Richer, N. Martinet, J. Paysant, and J. B. de Graaf, "Classification of Phantom Finger, Hand, Wrist, and Elbow Voluntary Gestures in Transhumeral Amputees With sEMG," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 25, no. 1, pp. 71–80, jan 2017.
- [14] Y. Zhang, Y. Liao, X. Wu, L. Chen, Q. Xiong, Z. Gao, X. Zheng, G. Li, and W. Hou, "Non-Uniform Sample Assignment in Training Set Improving Recognition of Hand Gestures Dominated with Similar Muscle Activities," *Front. Neurobot.*, vol. 12, feb 2018.
- [15] W.-T. Shi, Z.-J. Lyu, S.-T. Tang, T.-L. Chia, and C.-Y. Yang, "A bionic hand controlled by hand gesture recognition based on surface EMG signals: A preliminary study," *Biocybern. Biomed. Eng.*, vol. 38, no. 1, pp. 126–135, 2018.
- [16] Y. Sun, C. Li, G. Li, G. Jiang, D. Jiang, H. Liu, Z. Zheng, and W. Shu, "Gesture Recognition Based on Kinect and sEMG Signal Fusion," *Mob. Networks Appl.*, pp. 1–9, jan 2018. [Online]. Available: <http://link.springer.com/10.1007/s11036-018-1008-0>
- [17] A. Altamirano, A. Vera, R. Munoz, L. Leija, and D. Wolf, "Time and Frequency Patterns Identification of sEMG Signals Using Hilbert-Huang Transform," *IEEE Lat. Am. Trans.*, vol. 15, no. 10, pp. 1881–1887, oct 2017.
- [18] Thalmic Labs Inc., "Myo Armband," 2013. [Online]. Available: <https://www.myo.com/>
- [19] P.-J. Gonzalo and A. Holgado-Terriza Juan, "Control of home devices based on hand gestures," in *2015 IEEE 5th Int. Conf. Consum. Electron. - Berlin*. IEEE, sep 2015, pp. 510–514.
- [20] A. Boyali and N. Hashimoto, "Spectral Collaborative Representation based Classification for hand gestures recognition on electromyography signals," *Biomed. Signal Process. Control*, vol. 24, pp. 11–18, 2016.
- [21] A. G. Jaramillo and M. E. Benalcazar, "Real-time hand gesture recognition with EMG using machine learning," in *2017 IEEE Second Ecuador Tech. Chapters Meet.* IEEE, oct 2017, pp. 1–5.
- [22] S. Benatti, S. Member, F. Casamassima, S. Member, and B. Milosevic, "A Versatile Embedded Platform for EMG Acquisition and Gesture Recognition," *Biomed. Circuits Syst. IEEE Trans.*, vol. 9, no. 5, pp. 620–630, 2015.
- [23] A. A. Hidayat, Z. Arief, and H. Yuniarti, "LOVETT scalling with MYO armband for monitoring finger muscles therapy of post-stroke people," in *2016 Int. Electron. Symp.*, vol. 3, no. 2. IEEE, sep 2016, pp. 66–70.

- [24] Y. Du, W. Jin, W. Wei, Y. Hu, and W. Geng, "Surface EMG-Based Inter-Session Gesture Recognition Enhanced by Deep Domain Adaptation," *Sensors*, vol. 17, no. 3, p. 458, feb 2017. [Online]. Available: <http://www.mdpi.com/1424-8220/17/3/458>
- [25] U. Côté-Allard, C. L. Fall, A. Drouin, A. Campeau-Lecours, C. Gosselin, K. Glette, F. Laviolette, and B. Gosselin, "Deep Learning for Electromyographic Hand Gesture Signal Classification by Leveraging Transfer Learning," jan 2018.
- [26] C. Amma, T. Krings, J. Böer, and T. Schultz, "Advancing Muscle-Computer Interfaces with High-Density Electromyography," in *Proc. 33rd Annu. ACM Conf. Hum. Factors Comput. Syst.* ACM Press, 2015, pp. 929–938.
- [27] M. Atzori, A. Gijsberts, C. Castellini, B. Caputo, A.-G. M. Hager, S. Elsig, G. Giatsidis, F. Bassetto, and H. Müller, "Electromyography data for non-invasive naturally-controlled robotic hand prostheses," *Sci. Data*, vol. 1, p. 140053, dec 2014.
- [28] T. Baldacchino<sup>1</sup>, W. R. Jacobs, S. R. Anderson, K. Worden, and J. Rowson, "Simultaneous Force Regression and Movement Classification of Fingers via Surface EMG within a Unified Bayesian Framework," *Front. Bioeng. Biotechnol.*, vol. 6, p. 13, 2018.
- [29] J. Wei, Q. Meng, and A. Badii, "Classification of Human Hand Movements Using Surface EMG for Myoelectric Control," 2017, pp. 331–339.
- [30] B. Milosevic, S. Benatti, and E. Farella, "Design challenges for wearable EMG applications," in *Des. Autom. Test Eur. Conf. Exhib.* IEEE, mar 2017, pp. 1432–1437.
- [31] J. Too, A. Abdullah, N. M. Saad, N. M. Ali, and T. Zawawi, "Deep convolutional neural network for featureless electromyogram pattern recognition using time-frequency distribution," *Sensor Letters*, vol. 16, no. 2, pp. 92–99, 2018.
- [32] A. Ebied, E. Kinney-Lang, L. Spyrou, and J. Escudero, "Muscle activity analysis using higher-order tensor models: Application to shared muscle synergy identification," *arXiv preprint arXiv:1806.01783*, 2018.
- [33] J. Wei, Q. Meng, and A. Badii, "Classification of human hand movements using surface emg for myoelectric control," in *Advances in Computational Intelligence Systems.* Springer, 2017, pp. 331–339.
- [34] M. C. Tosin, M. Majolo, R. Chedid, V. H. Cene, and A. Balbinot, "sEMG feature selection and classification using SVM-RFE," in *2017 39th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.* IEEE, jul 2017, pp. 390–393.
- [35] F. Bian, R. Li, and P. Liang, "SVM based simultaneous hand movements classification using sEMG signals," in *2017 IEEE Int. Conf. Mechatronics Autom.* IEEE, 2017, pp. 427–432.
- [36] A. Phinyomark and E. Scheme, "A feature extraction issue for myoelectric control based on wearable EMG sensors," in *2018 IEEE Sensors Appl. Symp.* IEEE, mar 2018, pp. 1–6.
- [37] A. Oleinikov, B. Abibullaev, A. Shintemirov, and M. Folgheraiter, "Feature extraction and real-time recognition of hand motion intentions from EMGs via artificial neural networks," in *2018 6th Int. Conf. Brain-Computer Interface.* IEEE, 2018, pp. 1–5.
- [38] Y. Wu, S. Liang, L. Zhang, Z. Chai, C. Cao, and S. Wang, "Gesture recognition method based on a single-channel sEMG envelope signal," *EURASIP J. Wirel. Commun. Netw.*, vol. 2018, no. 1, p. 35, 2018.
- [39] G. R. Naik, *Applications, Challenges, and Advancements in Electromyography Signal Processing*, ser. Advances in Medical Technologies and Clinical Practice, G. R. Naik, Ed. IGI Global, 2014.
- [40] A. Phinyomark, F. Quaine, S. Charbonnier, C. Serviere, F. Tarpin-Bernard, and Y. Laurillau, "EMG feature evaluation for improving myoelectric pattern recognition robustness," *Expert Syst. Appl.*, vol. 40, no. 12, pp. 4832–4840, sep 2013.

- [41] M. Hakonen, H. Piitulainen, and A. Visala, "Current state of digital signal processing in myoelectric interfaces and related applications," *Biomed. Signal Process. Control*, vol. 18, pp. 334–359, apr 2015.
- [42] S. Pizzolato, L. Tagliapietra, M. Cognolato, M. Reggiani, H. Müller, and M. Atzori, "Comparison of six electromyography acquisition setups on hand movement classification tasks," *PLoS One*, vol. 12, no. 10, p. e0186132, oct 2017.
- [43] G. Chandrashekar and F. Sahin, "A survey on feature selection methods," *Comput. Electr. Eng.*, vol. 40, no. 1, pp. 16–28, 2014.
- [44] G. Purushothaman and R. Vikas, "Identification of a feature selection based pattern recognition scheme for finger movement recognition from multichannel EMG signals," *Australas. Phys. Eng. Sci. Med.*, vol. 41, no. 2, pp. 549–559, jun 2018.
- [45] J. Kim, S. Mastnik, and E. André, "EMG-based hand gesture recognition for realtime biosignal interfacing," in *Proc. 13th Int. Conf. Intell. user interfaces - IUI '08*. New York, New York, USA: ACM Press, 2008, p. 30. [Online]. Available: <http://portal.acm.org/citation.cfm?doid=1378773.1378778>
- [46] Y. Liu, X. Wang, and K. Yan, "Hand gesture recognition based on concentric circular scan lines and weighted K-nearest neighbor algorithm," *Multimed. Tools Appl.*, vol. 77, no. 1, pp. 209–223, jan 2018. [Online]. Available: <http://link.springer.com/10.1007/s11042-016-4265-6>
- [47] X. HU, J. KAN, and W. LI, "Classification of surface electromyogram signals based on directed acyclic graphs and support vector machines," *TURKISH J. Electr. Eng. Comput. Sci.*, vol. 26, no. 2, pp. 732–742, mar 2018.
- [48] W.-J. Li, C.-Y. Hsieh, L.-F. Lin, and W.-C. Chu, "Hand gesture recognition for post-stroke rehabilitation using leap motion," in *2017 Int. Conf. Appl. Syst. Innov.* IEEE, may 2017, pp. 386–388. [Online]. Available: <http://ieeexplore.ieee.org/document/7988433/>
- [49] N. Siddiqui and R. H. M. Chan, "A wearable hand gesture recognition device based on acoustic measurements at wrist," in *2017 39th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.* IEEE, jul 2017, pp. 4443–4446. [Online]. Available: <https://ieeexplore.ieee.org/document/8037842/>
- [50] Y. Du, W. Jin, W. Wei, Y. Hu, and W. Geng, "Surface emg-based inter-session gesture recognition enhanced by deep domain adaptation," *Sensors*, vol. 17, no. 3, p. 458, 2017.
- [51] K. Xing, Z. Ding, S. Jiang, X. Ma, K. Yang, C. Yang, X. Li, and F. Jiang, "Hand Gesture Recognition Based on Deep Learning Method," in *2018 IEEE Third Int. Conf. Data Sci. Cybersp.* IEEE, jun 2018, pp. 542–546. [Online]. Available: <https://ieeexplore.ieee.org/document/8411908/>
- [52] O. K. Oyedotun and A. Khashman, "Deep learning in vision-based static hand gesture recognition," *Neural Comput. Appl.*, vol. 28, no. 12, pp. 3941–3951, dec 2017. [Online]. Available: <http://link.springer.com/10.1007/s00521-016-2294-8>

# 1

## CONCEPTOS PRELIMINARES

### Índice

---

<b>1.1 Anatomía de la mano</b> . . . . .	<b>8</b>
1.1.1 Fisiología de la Mano . . . . .	8
1.1.2 Huesos y Articulaciones de la Mano . . . . .	8
1.1.3 Dedos de la Mano . . . . .	8
1.1.4 Flexión y Extensión de los dedos de la Mano . . . . .	8
1.1.5 Músculos del antebrazo . . . . .	8
1.1.6 Electromiografía (EMG) . . . . .	9
1.1.7 Electromiografía Superficial (sEMG) . . . . .	9
1.1.8 Potenciales de Unidad Motora . . . . .	9
<b>1.2 Instrumentos</b> . . . . .	<b>10</b>
1.2.1 Brazaletes de Electrodo . . . . .	10
1.2.2 Sensores flexibles . . . . .	10
<b>1.3 Descomposición de Modo Empírico (EMD)</b> . . . . .	<b>11</b>
<b>1.4 Estimación de características</b> . . . . .	<b>11</b>
1.4.1 Características en el dominio del tiempo . . . . .	11
1.4.2 Características en el dominio de Frecuencia . . . . .	13
1.4.3 Características en el dominio de Tiempo-Frecuencia . . . . .	15
<b>1.5 Reducción de dimensión y Clasificación</b> . . . . .	<b>15</b>
1.5.1 Selección Secuencial hacia Adelante (SFS) . . . . .	15
1.5.2 Análisis de Componentes Principales (PCA) . . . . .	15
1.5.3 $k$ -vecinos más cercanos ( $k$ -NN) . . . . .	15
1.5.4 Máquinas de Vectores de Soporte (SVM) . . . . .	15
1.5.5 Análisis discriminante lineal (LDA) . . . . .	16
1.5.6 Medidas de rendimiento de los clasificadores . . . . .	16
<b>Referencias</b> . . . . .	<b>16</b>

---

### INTRODUCCIÓN

En este capítulo se introducen las definiciones, conceptos fundamentales y elementos teóricos en los que se soporta el desarrollo de esta tesis. Este capítulo está dividido de la siguiente manera: En la Sección 1.1 se definen los conceptos relacionados con la anatomía de la mano, en la Sección 1.2 los instrumentos utilizados para la adquisición de los datos, en la Sección 1.3 se explica teóricamente el método de Descomposición de Modo Empírico, la Sección 1.4 se concentra en describir las técnicas de estimación de características, y por último, en la Sección 1.5 se presentan los conceptos teóricos de la reducción de dimensión y clasificadores implementados.

## 1.1. ANATOMÍA DE LA MANO

### 1.1.1. FISIOLÓGÍA DE LA MANO

La mano y la muñeca están compuestas por un conjunto de huesos y articulaciones que forman una estructura cinemática articulada compleja, cuya función es la fijación y manipulación de objetos de diferentes formas, tamaños y texturas [1], ver Figura 1.1.

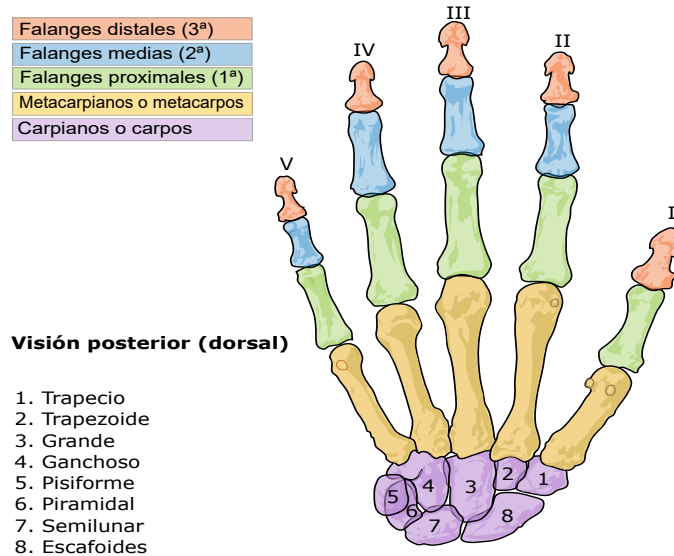


Figura 1.1: Huesos y Articulaciones de la mano. Adaptado de [2]

### 1.1.2. HUESOS Y ARTICULACIONES DE LA MANO

La mano está constituida por cuatro grupos principales de articulaciones: Articulación Distal Interfalángica (DIF), Proximal Interfalángica (PIF), Metacarpofalángica (MCF) y Carpometacarpiana (CMC), éstos son constituidos por los 27 huesos que contiene la mano incluyendo los de la muñeca: 14 falanges de los dedos, 5 metacarpianos y 8 carpianos [3].

### 1.1.3. DEDOS DE LA MANO

Los dedos son órganos que permiten percibir por medio del tacto cualidades de los objetos y medios como la temperatura, dureza, suavidad, aspereza, entre otros. La mano contiene cinco dedos designados, dedo pulgar también conocido como el primer dedo, seguido del índice, medio, anular y meñique, estos dedos están formados por tres falanges: falange distal, media y proximal, a excepción del dedo pulgar que cuenta solo con falange distal y proximal [4].

### 1.1.4. FLEXIÓN Y EXTENSIÓN DE LOS DEDOS DE LA MANO

El movimiento de flexión y extensión se realiza mediante la articulación metacarpofalángica, donde la flexión MCF de los dedos de la mano tiene un rango de 0-90° — valores normales descritos por la Asociación para el Estudio de la Osteosíntesis (AO) y de 0-90° para la Academia Americana de Cirujanos Ortopédicos (AAOS); la extensión MCF de los dedos de la mano es: 0-30° (AO) y 0-45° (AAOS). Los dedos índice y meñique cuentan con una extensión metacarpofalángica mayor a los demás dedos porque disponen de un tendón extensor propio [5].

### 1.1.5. MÚSCULOS DEL ANTEBRAZO

El antebrazo está limitado por su cara superior con el brazo mediante el codo y por su cara inferior con la mano mediante la articulación de la muñeca, en la Figura 1.2 se pueden observar los músculos del antebrazo, los cuales están divididos en dos [6]:



1. **Músculos anteriores del antebrazo**, están compuestos por:

- Capa Superficial
- Capa Intermedia: Músculo Flexor superficial de los dedos.
- Capa Profunda: Músculo Flexor profundo de los dedos y Músculo Flexor largo del pulgar.

2. **Músculos posteriores del antebrazo**, están compuestos por:

- Capa Superficial: Músculo Extensor común de los dedos y Músculo Extensor del meñique.
- Capa Profunda: Músculo Separador largo del pulgar, Músculo Extensor corto del pulgar, Músculo Extensor del índice y Músculo Extensor largo del pulgar.

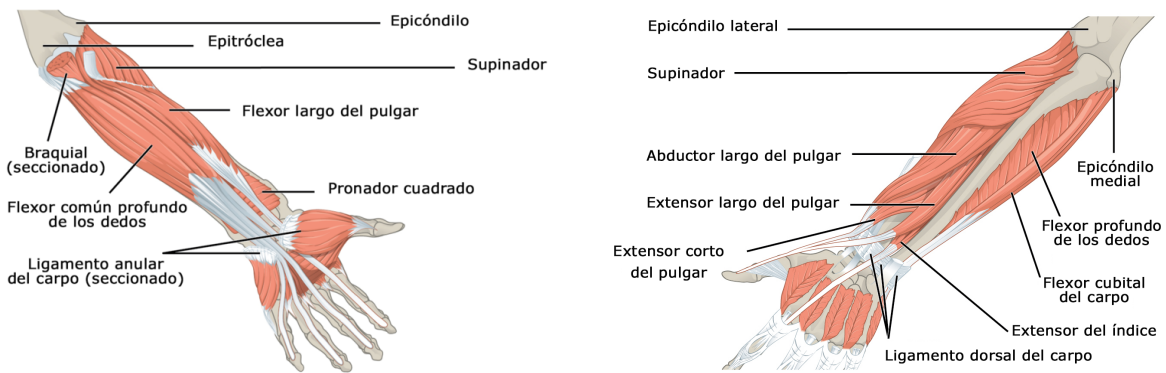


Figura 1.2: Músculos del antebrazo. Tomado de [7]

### 1.1.6. ELECTROMIOGRAFÍA (EMG)

Consiste en el registro de las variaciones de voltaje que se generan en las fibras musculares como expresión de la despolarización de sus membranas cuando se contraen, bien sea voluntariamente o como respuesta a un estímulo eléctrico [8]. La EMG ofrece un fácil acceso a la fisiología o la fisiopatología del sistema neuromuscular, permitiendo estudiar y registrar el comportamiento bioeléctrico muscular utilizando electrodos. Existen electrodos de superficie (sobre la piel), internos (dentro de la piel hasta el tejido muscular) y microelectrodos (nivel celular) [9], la diferencia entre estos electrodos es que los de superficie no requieren de una intervención quirúrgica y no presenta molestias para el sujeto, mientras que los internos y microelectrodos sí la requieren y su inserción es muy dolorosa, además requiere de un personal especializado para su realización.

### 1.1.7. ELECTROMIOGRAFÍA SUPERFICIAL (SEMG)

Registra la actividad bioeléctrica generada en el músculo durante su contracción de forma no invasiva, permitiendo el análisis de patrones de la actividad muscular para establecer planes de monitoreo o tratamiento de los músculos. No obstante, no permite valorar la musculatura profunda y aporta menos amplitud y ruido que los electromiogramas de aguja [10].

### 1.1.8. POTENCIALES DE UNIDAD MOTORA

Se define como unidad motora (UM) la neurona motora y las fibras musculares que inerva, las cuales están ampliamente dispersas en todo el músculo. Al activarse una unidad motora, el impulso llamado potencial de acción se desplaza de la neurona motora hacia el músculo. El potencial de acción se transmite a través de la unión neuromuscular (área donde el nervio hace contacto con el músculo), y se obtiene un potencial en todas las fibras musculares inervadas por la unidad motora particular. La suma de toda esta actividad eléctrica se conoce como Potenciales de acción de la unidad motora (MUAP) [11]. Las señales EMG obtienen el registro de



las MUAP por medio de sensores (electrodos) cuando sólo dos o tres UM están activos en la zona de los sensores, por lo general es posible identificar visualmente la mayoría de los potenciales de acción individuales UM porque la incidencia de la superposición entre los potenciales individuales de acción UM es relativamente bajo. Sin embargo, cuando la señal de EMG contiene la actividad de cuatro o más UMs los potenciales de acción individuales se convierten, en gran parte, indistinguibles a simple vista debido a la incidencia de la superposición entre dos o más potenciales de acción UM pueden tener similitud. Las complejidades que ocurren dentro de una señal son 1) superposición de los potenciales de acción de diferentes UM, 2) amplio rango dinámico de las amplitudes entre los potenciales de acción de los distintos UMs de interés, 3) cambio de forma a través de los diferentes potenciales de acción de cada UM y 4) la similitud de la forma en diversos momentos entre los potenciales de acción de las diferentes UMs. Estos fenómenos pueden actuar al mismo tiempo con otros para hacer de la descomposición una tarea difícil.

## 1.2. INSTRUMENTOS

### 1.2.1. BRAZALETE DE ELECTRODOS

El dispositivo Myo Armband<sup>®</sup> es fabricado por los laboratorios Thalmic, y se utiliza para capturar las señales sEMG producidas por la contracción de los músculos del antebrazo de un sujeto por medio de múltiples sensores (electrodos, giroscopio, acelerómetro y magnetómetro), además es usado en aplicaciones que requieran detectar gestos y movimientos de la mano. Este sensor es inalámbrico (Smart Wireless Technology), por lo que presenta algunas ventajas con respecto a los electrodos superficiales, entre ellos su diseño permite la expansión o contracción a un rango de circunferencia entre 19 cm y 34 cm. En la Tabla 1.1 se muestran las especificaciones técnicas más importantes del brazalete Myo Armband<sup>®</sup> [12].

Tabla 1.1: Especificación Técnica MYO Armband

Especificación Técnica	MYO Armband
Procesador	ARM Cortex M4
Frecuencia	200 Hz
Tamaño	19-34 cm
Peso	93 gramos
Espesor	0.45 pulgadas
Sistema Operativo	Windows, Mac, iOS, Android
Electrodos	8 Acero inoxidable quirúrgico
Comunicación	Bluetooth
Batería	Ion de Litio
Carga	Micro USB

Para esta tesis el sensor Myo Armband<sup>®</sup> se usó en la parte más ancha del antebrazo, debido a que la señal es más fuerte en esos músculos porque permiten realizar la extensión y flexión de los dedos de la mano detectando mejor las señales sEMG, por tal motivo, es necesario verificar que quede fijo y con una presión soportable al sujeto. El sensor MYO Armband se utiliza para capturar las señales sEMG del sujeto, las cuales son usadas para el reconocimiento del movimiento individual de los dedos de la mano.

### 1.2.2. SENSORES FLEXIBLES

El sensor Flexible 56 mm Modelo SEN\_0628 es patentado debido a su tecnología por la empresa Spectra Symbol, este sensor se ha utilizado en aplicaciones de robótica, dispositivos médicos, entre otras [13, 14]. El sensor consta de dos lados, uno contiene tinta de polímero con partículas conductoras incrustadas en ella, cuando el sensor está en una posición recta las partículas permiten a la tinta una resistencia aproximada de 10  $k\Omega$ , pero si se flexiona lejos de la tinta a 90 grados, las partículas se separan, aumentando la resistencia a 13  $k\Omega$ , cuando el sensor vuelve a su posición recta, la resistencia regresa a su valor original [15]. El otro lado del sensor consta de un pegante para situarlo de manera fija en una superficie, por tal motivo, el sensor está diseñado para flexionarse en una sola dirección, de lo contrario el sensor podría dañarse. En la Tabla 1.2 se pueden observar los

datos técnicos.

Tabla 1.2: Datos Técnicos Sensor Flexible 56 mm

Especificación Técnica	Sensor Flexible 56mm
Resistencia Posición recta	10 kΩ ± 30%
Ciclo de vida	>1 millón
Altura	0.43 mm
Rango de Temperatura	-35°C - + 80°C
Resistencia a la curvatura	Mínimo 2 veces >a la resistencia plana 180°
Potencia	0.5 vatios continuos; 1 vatio pico

### 1.3. DESCOMPOSICIÓN DE MODO EMPÍRICO (EMD)

Método que permite descomponer una señal  $x(t)$  como una suma de componentes de amplitud (AM) y frecuencia (FM). Cada una de estas componentes son llamadas Funciones de Modo Intrínsecas (IMFs) o Modos. La descomposición se basa en la escala de tiempo local de la señal y produce funciones de base adaptativas [1].

Los IMFs deben cumplir lo siguiente:

- La cantidad de números extremos (máximos y mínimos) y la cantidad de cruces por cero deben ser iguales o diferir a lo sumo en uno.
- La media local, definida como el valor medio de las envolventes superior e inferior, debe ser nula para todo punto.

Una señal  $x(t)$  puede descomponerse utilizando el método EMD, a partir de la ecuación (1.1):

$$x(t) = \sum_{j=1}^n c_j + r_n \quad (1.1)$$

Donde  $c_j$  es un IMF. De este modo, se puede obtener una descomposición de la señal en  $n$  IMFs, y un residuo  $r_n$ , el cual expresa la tendencia media de  $x(t)$ . Los valores IMFs  $c_1$ ,  $c_2$  hasta  $c_n$ , incluyen diferentes bandas de frecuencia que van desde altas a bajas, los cuales cambian con la variación de la señal  $x(t)$  debido a que son calculados de forma empírica [2].

### 1.4. ESTIMACIÓN DE CARACTERÍSTICAS

#### 1.4.1. CARACTERÍSTICAS EN EL DOMINIO DEL TIEMPO

Las características del dominio del tiempo se calculan en función de la amplitud de la señal y son muy utilizadas en el reconocimiento de patrones de señales sEMG, ya que permiten un procesamiento fácil y una evaluación rápida de las señales, ya que no requieren una transformación. Las características utilizadas en este dominio son:

- **Valor Integrado de EMG (IEMG):** Se encuentra calculando la suma de los valores absolutos de las muestras de la señal de EMG y se define de la siguiente manera [16]:

$$IEMG = \sum_{j=1}^L |x_j| \quad (1.2)$$

Donde  $x_j$  es el valor de cada parte de la muestra, y  $L$  es la longitud del segmento del tiempo.

- **Desviación Estándar:** Representa qué tan separados están los datos con respecto a la media, y su expresión matemática es [17]:

$$x_{std} = \sqrt{\frac{\sum_{j=1}^L (x_j - \bar{x})^2}{L-1}} \quad (1.3)$$

Donde  $\bar{x}$  es la media de la señal.

- **Diferencia del Valor Absoluto de la Desviación Estándar (DASDV):** Es la raíz cuadrada del promedio del cuadrado de la diferencia entre las amplitudes de sEMG adyacentes sobre el segmento de tiempo. En otras palabras es el RMS de la longitud de onda EMG y se expresa como [16].

$$DASDV = \sqrt{\frac{1}{L-1} \sum_{j=1}^{L-1} (x_{j+1} - x_j)^2} \quad (1.4)$$

- **Valor Medio Absoluto (MAV):** Estima el promedio del valor absoluto de los datos en un determinado segmento de la siguiente manera [18]:

$$MAV = \frac{1}{L} \sum_{j=1}^L |x_j| \quad (1.5)$$

- **Valor Absoluto Medio Modificado 1 (MMAV1):** Es una extensión del MAV utilizando la función de ventana de ponderación  $w_j$ , así [19]:

$$MMAV1 = \frac{1}{L} \sum_{j=1}^L w_j |x_j| \quad (1.6)$$

$$w(j) = \begin{cases} 1, & 0.25L \leq j \leq 0.75L \\ 0.5, & \text{Otros} \end{cases}$$

- **Valor Absoluto Medio Modificado 2 (MMAV2):** Es otra extensión de MAV, pero en esta ecuación se mejora la función de ventana de ponderación  $w_j$ , ya que es una función continua [19].

$$MMAV2 = \frac{1}{L} \sum_{j=1}^L w_j |x_j| \quad (1.7)$$

$$w(j) = \begin{cases} 1, & 0.25L \leq j \leq 0.75L \\ 4j/L, & 0.25L > j \\ 4(j-L), & 0.25L < j \end{cases}$$

- **Raíz media cuadrada (RMS):** Caracteriza la señal de acuerdo a la estimación del contenido de energía, en relación con su amplitud, en un determinado intervalo de tiempo, y se expresa como [20]:

$$RMS = \sqrt{\frac{1}{L} \sum_{j=1}^L x_j^2} \quad (1.8)$$

- **Varianza (VAR):** Es el promedio del valor cuadrado de la amplitud de la señal sEMG. La ecuación se define como [20]:

$$VAR = \frac{1}{L} \sum_{j=1}^L (x_j - \bar{x})^2 \quad (1.9)$$

- **Longitud de forma de onda (WL):** Es una longitud acumulada de la forma de onda sEMG en un segmento de tiempo, se define en la siguiente ecuación [18]:

$$WL = \sum_{j=1}^{L-1} |x_{j+1} - x_j| \quad (1.10)$$

- **Cruce por cero (ZC):** Es el número de veces que la señal sEMG cruzan el nivel de amplitud cero. Se debe de incluir una condición de umbral  $\epsilon$  en amplitud para evitar los cruces por cero producidos por el ruido de la señal, el cálculo se define como [18]:

$$\{x_j > 0 \text{ y } x_{j+1} < 0\} \text{ o } \{x_j < 0 \text{ y } x_{j+1} > 0\} \text{ y } |x_j - x_{j+1}| \geq \epsilon \quad (1.11)$$

- **Cambios en la pendiente de la señal (SSC):** Es el número de cambios entre las pendientes positivas y negativas. Se debe incluir un umbral  $\epsilon$  para evitar el ruido, dadas tres muestras consecutivas  $x_{j-1}$ ,  $x_j$  y  $x_{j+1}$ , el cambio de signo de pendiente se incrementa si [18]:

$$\{x_j > x_{j-1} \text{ y } x_j > x_{j+1}\} \text{ or } \{x_j < x_{j-1} \text{ y } x_j < x_{j+1}\} \text{ y } |x_j - x_{j+1}| \geq \epsilon \text{ o } |x_j - x_{j-1}| \geq \epsilon \quad (1.12)$$

- **Amplitud Willison (WAMP):** Calcula el número de veces que el valor absoluto de la diferencia entre la amplitud de señal EMG de dos muestras consecutivas ( $x_j$  y  $x_{j+1}$ ) excede un umbral  $\epsilon$  predeterminado [16].

$$WAMP = \sum_{j=1}^{L-1} f(|x_j - x_{j+1}|) \quad (1.13)$$

$$f(x) = \begin{cases} 1 & x > \epsilon \\ 0 & \text{Otros} \end{cases}$$

- **Integral del cuadrado simple (SSI):** Es una suma de los valores cuadrados de la amplitud de la señal EMG. En general, este parámetro se define como la característica de la energía de señal sEMG, se puede expresar como [19]:

$$SSI = \sum_{j=1}^L (|x_j|^2) \quad (1.14)$$

- **Tasa de Porcentaje de Myopulse (MYOP):** Es el valor promedio de salida myopulse que se define como uno, cuando el valor absoluto de la señal EMG excede un valor de umbral  $\epsilon$  predefinido como [16]:

$$MYOP = \frac{1}{L} \sum_{j=1}^L [f(|x_j|)] \quad (1.15)$$

$$f(x) = \begin{cases} 1, & \text{if } x \geq \epsilon \\ 0, & \text{Otros} \end{cases}$$

### 1.4.2. CARACTERÍSTICAS EN EL DOMINIO DE FRECUENCIA

Las características del dominio de frecuencia se basan en la densidad del espectro de potencia (PSD) de la señal sEMG y se calcula mediante métodos paramétricos, sin embargo, estas características en comparación con las características del dominio del tiempo requieren más cálculos y tiempo para calcular.

- **Frecuencia Mediana (FMD):** La frecuencia mediana divide en dos el espectro de densidad de potencia (PSD) [16].

$$FMD = \frac{1}{2} \sum_{j=1}^M PSD_j \quad (1.16)$$

Donde  $M$  es la longitud del PSD,  $j$  es la  $j$ -ésima línea de PSD.

- **Frecuencia Media (FMN):** Es la frecuencia promedio que se calcula como la suma del producto del espectro de potencia sEMG y la frecuencia dividida por la suma total de la intensidad del espectro [16].

$$FMN = \frac{\sum_{j=1}^M f_j PSD_j}{\sum_{j=1}^M PSD_j} \quad (1.17)$$

Donde  $M$  es la longitud del PSD y  $f_j = (j \cdot \text{tasa de muestreo}) / (2 * M)$ , y  $PSD_j$  es la  $j$ -ésima línea de la densidad del espectro de potencia.

- **Modulación de Frecuencia Mediana (MFMD):** Es la frecuencia a la que el espectro se divide en dos regiones con la misma amplitud, donde  $B_j$  es la amplitud y está dada por [19]:

$$MFMD = \frac{1}{2} \sum_{j=1}^M B_j \quad (1.18)$$

- **Modulación de Frecuencia Media (MFMN):** Es la suma del producto del espectro de amplitud  $B_j$  y la frecuencia  $f_j$ , dividida por la suma total de la intensidad espectral, viene dada por [19]:

$$FMN = \frac{\sum_{j=1}^M f_j B_j}{\sum_{j=1}^M B_j} \quad (1.19)$$

- **Tasa de Frecuencia (FR):** Se utiliza para distinguir la diferencia entre contracción y relajación de un músculo en el dominio de la frecuencia, mediante la aplicación de la transformada rápida de Fourier a las señales EMG en el dominio del tiempo [19].

$$FR_i = \frac{|F(\cdot)|_{i_{lowfreq}}}{|F(\cdot)|_{i_{highfreq}}} \quad (1.20)$$

Donde  $|F(\cdot)|_i$  es la transformada rápida de Fourier de la señal sEMG en  $j$ ,  $i_{lowfreq}$  es la banda de frecuencia baja, e  $i_{highfreq}$  es la banda de frecuencia alta.

- **Relación señal/ruido (SNR):** Se define como la relación entre la media y la desviación estándar [21].

$$SNR = \frac{\bar{x}}{x_{std}} \quad (1.21)$$

- **Frecuencia pico (PKF):** Frecuencia a la que se produce la potencia máxima durante la época. PKF es una frecuencia a la que se produce la potencia máxima de sEMG. Se puede expresar como [22]:

$$PKF = \max(PSD_j), \quad j = 1, \dots, M \quad (1.22)$$

- **Potencia Media (MNP):** Es la potencia promedio del espectro de potencia dentro de la época. Se define como [20]:

$$MNP = \frac{\sum_{j=1}^M PSD_j}{M} \quad (1.23)$$

### 1.4.3. CARACTERÍSTICAS EN EL DOMINIO DE TIEMPO-FRECUENCIA

La representación de tiempo-frecuencia puede localizar la energía de la señal tanto en tiempo como en frecuencia, permitiendo realizar análisis más fiables y más completos. Estas características generalmente requieren una transformación que podría ser computacionalmente pesada.

- **Transformada Wavelet Discreta (DWT):** Es una transformación donde una señal es integrada con una función o Wavelet madre desplazada en tiempo y en escala [23].

$$W_x(a, b) = \int x(t) \left( \frac{1}{\sqrt{a}} \right) \psi^* \left( \frac{t-b}{a} \right) dt \quad (1.24)$$

Donde  $x(t)$  es la señal a transformar,  $\psi^*$  es el complejo conjugado de la Wavelet madre y  $\psi \left( \frac{t-b}{a} \right)$  es la versión desplazada y escalada de la Wavelet madre en el tiempo  $b$  y escala  $a$ .

## 1.5. REDUCCIÓN DE DIMENSIÓN Y CLASIFICACIÓN

### 1.5.1. SELECCIÓN SECUENCIAL HACIA ADELANTE (SFS)

El objetivo de los algoritmos de selección de características es elegir una serie de características del conjunto de características extraídas que arroje un error de clasificación mínimo, es decir, obtiene las características más discriminantes del conjunto de características. En este sentido, el algoritmo SFS utiliza un procedimiento de búsqueda de abajo hacia arriba que comienza desde un conjunto vacío de características  $S$  y agrega gradualmente características seleccionadas al minimizar el error cuadrático medio (MSE) de alguna función de evaluación, comúnmente la medida de Fisher. En cada iteración, la característica que se incluirá en  $S$  se selecciona entre las características disponibles restantes y es la que tiene un mayor peso [24].

### 1.5.2. ANÁLISIS DE COMPONENTES PRINCIPALES (PCA)

PCA permite transformar un número de variables posiblemente correlacionadas en un número de variables no correlacionadas, llamadas componentes principales. El primer componente condensa la mayor cantidad de variabilidad posible del conjunto de datos y cada uno de los componentes restantes absorbe el resto. Es utilizado para reducir la dimensionalidad de un conjunto de datos multivariado. El valor de la varianza indica cuantos componentes principales se van a utilizar para el conjunto de datos, es decir, cuanto mayor sea la varianza de los datos, se considera que existe mayor información [25].

### 1.5.3. $k$ - VECINOS MÁS CERCANOS ( $k$ -NN)

Es un método no paramétrico de aprendizaje supervisado que tiene como argumento principal la distancia entre las muestras. El clasificador compara la nueva muestra con los  $k$ -vecinos más cercanos conocidos, y dependiendo de la similitud entre los atributos, el nuevo caso se ubicará en la clase que más se acerque al atributo más común entre ellos. El valor de  $k$  puede ser seleccionado teniendo un radio de comparación, usando diagramas de Voronoi, curvas de error o pruebas de validación [26].

### 1.5.4. MÁQUINAS DE VECTORES DE SOPORTE (SVM)

Las máquinas de vectores de soporte son clasificadores binarios. Las SVM producen un hiperplano que discrimina los datos en cuestión en sus clases correspondientes. Sin embargo, no siempre es posible separarlos correctamente, de ser así, el resultado del modelo no se puede generalizar a otros datos. Esto se conoce como sobreajuste. Para permitir algunos errores y reducir el sobreajuste, la SVM maneja un parámetro  $C$  que controla el equilibrio entre los errores de entrenamiento y las márgenes rígidas, creando un margen suave que permite una clasificación correcta. La función de costo de SVM se puede expresar en la ecuación (1.25):

$$\tau(w) = \arg \min_w \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \varepsilon_i \quad (1.25)$$

Donde  $w$  es un vector normal para el hiperplano y  $\varepsilon_i$  representa la penalización para el  $i$ -ésimo dato que no satisface la restricción de margen. Se pueden encontrar más detalles sobre SVM de margen suave en [27].

### 1.5.5. ANÁLISIS DISCRIMINANTE LINEAL (LDA)

Es un método de clasificación supervisado de variables cualitativas en el que dos o más grupos son conocidos a priori. Encuentra una combinación lineal de rasgos que caracterizan o separan dos o más clases de objetos o eventos, además esta relacionada con el análisis de varianza y análisis de regresión. LDA está estrechamente relacionado con PCA, ya que ambos se basan en transformaciones lineales, para el caso de PCA, la transformación se basa en minimizar el error cuadrático medio entre los vectores de los datos originales y los vectores de datos que pueden estimarse a partir de los vectores de datos de dimensionalidad reducida, y para el caso de LDA, la transformación se basa en maximizar una proporción de "varianza entre clases" con el objetivo de reducir la variación de datos en la misma clase y aumentar la separación entre clases [28].

### 1.5.6. MEDIDAS DE RENDIMIENTO DE LOS CLASIFICADORES

Para calcular el rendimiento de los clasificadores, se utilizan medidas como la sensibilidad y la especificidad, estimando matrices de confusión, que muestran la distribución entre una clase verdadera y la clase predicha por el clasificador usando etiquetas. Tiene cuatro posibles casos: si una instancia es positiva y se clasifica como positiva, se llama verdadero positivo (VP), si se califica como negativa, se cuenta como falso negativo (FN). Si la instancia es negativa y se clasifica como negativa, se considera como verdadero negativo (VN) y si se clasifica como positiva, se considera como un falso positivo (FP).

La sensibilidad, la especificidad, la exactitud y la media geométrica se describen en términos de VP, VN, FN y FP, tal como se indica en las ecuaciones (1.26), (1.27), (1.28), (1.29) respectivamente [29].

$$\text{Sensibilidad} = \frac{VP}{(VP + FN)} \quad (1.26)$$

$$\text{Especificidad} = \frac{VN}{(VN + FP)} \quad (1.27)$$

$$\text{Exactitud} = \frac{(VP + VN)}{(VP + FP + VN + FN)} \quad (1.28)$$

$$\text{Media geométrica} = \sqrt{\frac{VP}{(VP + FN)} \cdot \frac{VN}{(VN + FP)}} \quad (1.29)$$

La exactitud es la medida estándar utilizada para evaluar el rendimiento de los clasificadores, ya que permite saber que el valor medido está muy cerca del valor real. En términos más prácticos, tener exactitud del 100% significa que las etiquetas originales son exactamente iguales a las obtenidas por el algoritmo de clasificación. Además, la media geométrica también se usó para condensar algunos resultados porque tiene en cuenta tanto sensibilidad como especificidad.

## REFERENCIAS

- [1] A. T. Velázquez Sánchez, "Caracterización cinemática e implementación de una mano robótica multiarticulada," 2008.
- [2] Ascánder, "File:Scheme human hand bones-es-Com.svg," 2009. [Online]. Available: [https://commons.wikimedia.org/wiki/File:Scheme\\_human\\_hand\\_bones-es-Com.svg](https://commons.wikimedia.org/wiki/File:Scheme_human_hand_bones-es-Com.svg)
- [3] D. Le Vay, *Anatomía y fisiología humana*. Editorial Paidotribo, 2008.
- [4] N. Palastanga, D. Field, and R. Soames, *Anatomía y movimiento humano. Estructura y funcionamiento*. Editorial Paidotribo, 2007.
- [5] S. Hoppenfeld, *Exploración física de la columna vertebral y las extremidades*, 1979.
- [6] F. Delavier, *Guía de los movimientos de musculación. Descripción Anatómica*. Editorial Paidotribo, 2007.

- [7] CFCF, "File:1120 Muscles that Move the Forearm Antebrach. Prof. Flex. Sin esp.png," 2018. [Online]. Available: [https://commons.wikimedia.org/wiki/File:1120\\_Muscles\\_that\\_Move\\_the\\_Forearm\\_Antebrach\\_Prof\\_Flex\\_Sin\\_esp.png](https://commons.wikimedia.org/wiki/File:1120_Muscles_that_Move_the_Forearm_Antebrach_Prof_Flex_Sin_esp.png)
- [8] R. Merletti and P. A. Parker, *Electromyography: physiology, engineering, and non-invasive applications*. John Wiley & Sons, 2004, vol. 11.
- [9] K. Caballero, L. M. Duque, S. Ceballos, J. C. Ramirez, and A. Peláez, "Conceptos básicos para el análisis electromiográfico," *CES Odontología*, vol. 15, no. 1, pp. 41–50, 2002.
- [10] N. Massó, F. Rey, D. Romero, G. Gual, L. Costa, and A. Germán, "Surface electromyography applications," *Apunts Medicina de l' Esport (English Edition)*, vol. 45, no. 166, pp. 127–136, 2010.
- [11] J. V. Pinzón, R. P. Mayorga, and G. C. Hurtado, "Brazo robótico controlado por electromiografía," *Scientia Et Technica*, vol. 1, no. 52, pp. 165–173, 2012.
- [12] Thalmic Labs Inc., "Myo Armband," 2013. [Online]. Available: <https://www.myo.com/>
- [13] M. S. Rahman, R. A. Sultan, and N. Hasan, "Sensor based human movement controlled hydraulic and electrical robotic arm," in *Applied Mechanics and Materials*, vol. 860. Trans Tech Publ, 2017, pp. 1–6.
- [14] L. Liu, B. He, J. Zhuang, L. Zhang, and A. Lv, "Force measurement system for invisalign based on thin film single force sensor," *Measurement*, vol. 97, pp. 1–7, 2017.
- [15] Tdrobótica, "Datasheets-Sensor flexible 56 mm," p. 2, 2014. [Online]. Available: <https://cdn.sparkfun.com/datasheets/Sensors/ForceFlex/FLEXSENSORDATASHEET2014.pdf>
- [16] A. Phinyomark, F. Quaine, and Y. Laurillau, "The Relationship between Anthropometric Variables and Features of Electromyography Signal for Human-Computer Interface," in *Appl. Challenges, Adv. Electromyogr. Signal Process.*, G. R. Naik, Ed. France: IGI Global, 2014, ch. 15, pp. 321–353.
- [17] A. Phinyomark, A. Nuidod, P. Phukpattaranont, and C. Limsakul, "Feature Extraction and Reduction of Wavelet Transform Coefficients for EMG Pattern Classification," *Electron. Electr. Eng.*, vol. 122, no. 6, jun 2012. [Online]. Available: <http://www.eejournal.ktu.lt/index.php/elt/article/view/1816>
- [18] W.-T. Shi, Z.-J. Lyu, S.-T. Tang, T.-L. Chia, and C.-Y. Yang, "A bionic hand controlled by hand gesture recognition based on surface EMG signals: A preliminary study," *Biocybern. Biomed. Eng.*, vol. 38, no. 1, pp. 126–135, 2018.
- [19] E. J. Rechy-Ramirez and H. Hu, "Stages for developing control systems using emg and eeg signals: A survey," *School of Computer Science and Electronic Engineering, University of Essex*, pp. 1744–8050, 2011.
- [20] A. Phinyomark, P. Phukpattaranont, and C. Limsakul, "Feature reduction and selection for EMG signal classification," *Expert Syst. Appl.*, vol. 39, no. 8, pp. 7420–7431, jun 2012. [Online]. Available: <http://linkinghub.elsevier.com/retrieve/pii/S0957417412001200>
- [21] P.-G. Jung, G. Lim, S. Kim, and K. Kong, "A Wearable Gesture Recognition Device for Detecting Muscular Activities Based on Air-Pressure Sensors," *IEEE Trans. Ind. Informatics*, pp. 1–1, 2015. [Online]. Available: <http://ieeexplore.ieee.org/document/7045532/>
- [22] S. M. Naeem, A. F. Seddik, and M. A. Eldosoky, "New technique based on uterine electromyography non-linearity for preterm delivery detection," *Journal of Engineering and Technology Research*, vol. 6, no. 7, pp. 107–114, 2014.
- [23] L. Vega-Escobar, A. Castro-Ospina, and L. Duque-Munoz, "DWT-based feature extraction for motor imagery classification," in *6th Latin-American Conf. Networked Electron. Media (LACNEM 2015)*. Institution of Engineering and Technology, 2015, pp. 3 (6 .)-3 (6 .). [Online]. Available: <http://digital-library.theiet.org/content/conferences/10.1049/ic.2015.0309>



- 
- [24] V. F. Rodríguez-Galiano, J. A. Luque-Espinar, M. Chica-Olmo, and M. P. Mendes, "Feature selection approaches for predictive modelling of groundwater nitrate pollution: An evaluation of filters, embedded and wrapper methods," *Sci. Total Environ.*, vol. 624, pp. 661–672, may 2018.
- [25] Y. Aït-Sahalia and D. Xiu, "Principal component analysis of high frequency data," *Journal of the American Statistical Association*, no. just-accepted, 2017.
- [26] P. Azaripasand, A. Maleki, and A. Fallah, "Classification of ADLs using muscle activation waveform versus thirteen EMG features," in *2015 22nd Iran. Conf. Biomed. Eng.* IEEE, nov 2015, pp. 189–193.
- [27] G. A. Betancourt, "Las máquinas de soporte vectorial (SVMs)," *Scientia et technica*, vol. 1, no. 27, 2005.
- [28] C. Li and B. Wang, "Fisher linear discriminant analysis," 2017.
- [29] L. Vega-Escobar, A. Castro-Ospina, and L. Duque-Muñoz, "Feature extraction schemes for bci systems," in *Signal Processing, Images and Computer Vision (STSIVA), 2015 20th Symposium on.* IEEE, 2015, pp. 1–6.

# 2

## ADQUISICIÓN DE DATOS

### Índice

---

<b>2.1 Prototipo de Adquisición</b> . . . . .	<b>19</b>
<b>2.2 Protocolo experimental</b> . . . . .	<b>20</b>
<b>2.3 Adquisición base de datos</b> . . . . .	<b>21</b>
<b>2.4 Etiquetado Automático</b> . . . . .	<b>22</b>
<b>Referencias</b> . . . . .	<b>30</b>

---

### INTRODUCCIÓN

Las señales sEMG se han convertido en una herramienta muy utilizada para el reconocimiento de gestos y movimientos de los dedos, debido a la facilidad con la que se puede adquirir de manera no invasiva sin generar incomodidad a los sujetos. Algunas bases de datos encontradas en la literatura como CapgMyo [1], Myo Dataset [2], csl-hdemg [3] y Ninapro [4], utilizan electrodos superficiales o sensores novedosos para adquirir señales electromiográficas y realizar la posterior etapa de reconocimiento. Para realizar el aprendizaje automático, estas bases de datos son etiquetadas manualmente cuando la persona realiza el gesto siguiendo un estímulo visual o por secuencia de los movimientos, sin embargo, esta manera de etiquetar puede generar errores debido a que los movimientos realizados por el sujeto pueden ser diferentes a los sugeridos por el estímulo visual, generando la necesidad de realizar un proceso de re-etiquetado de los datos. Por otro lado, las bases de datos contienen pocos gestos que se pueden ver como combinaciones de movimientos de múltiples dedos, por lo tanto, si se reconoce los movimientos individuales de los dedos, es posible realizar 27 combinaciones entre los dedos (gestos), debido a que el dedo pulgar es capaz de tocar punta a punta los dedos índice, medio, anular y meñique con una combinación de aducción-abducción y flexión-extensión, incrementando el número de gestos [5]. En este Capítulo se explican los aspectos relacionados con la adquisición de señales de electromiografía superficial para el reconocimiento de los movimientos individuales de los dedos, el cual está compuesta por 5 secciones. En la sección 2.1 se explica el prototipo de adquisición, en la sección 2.2 el protocolo experimental de adquisición, la adquisición de la base de datos se resume en la sección 2.3, y por último, en la sección 2.4 se propone el etiquetado automático de la base de datos para el posterior reconocimiento.

### 2.1. PROTOTIPO DE ADQUISICIÓN

Las señales sEMG son registradas mediante el brazalete Myo Armband<sup>®</sup>, este dispositivo contiene 8 electrodos de acero inoxidable y la comunicación es inalámbrica [6], por lo que presenta algunas ventajas con respecto a los electrodos superficiales, entre ellos su diseño al ser inalámbrico, ya que no requiere de uso excesivo de cables y permite la expansión o contracción a un rango de circunferencia entre 19 cm y 34 cm. Además, la ubicación del dispositivo en los sujetos no necesita de un estudio minucioso de la fisiología de los músculos donde se va a adquirir las señales electromiográficas.

Las señales del dispositivo Myo Armband<sup>®</sup> son enviadas inalámbricamente a un receptor Bluetooth HT010 utilizando MyoBridge Firmware, este bluetooth se conecta por comunicación serial a un microcontrolador Feather Bluefruit-32U4 alimentado con una batería de 3.7 voltios, 400mA, y a su vez las señales adquiridas por los sensores flexibles también son enviadas al mismo microcontrolador, esto con el objetivo de que ambas señales estén sincronizadas para después realizar un pre-proceso de etiquetación automático para el posterior aprendizaje automático de los movimientos individuales de los dedos de la mano, el cuál se explicará en la sección 2.4.

Es importante aclarar que el dispositivo Myo Armband<sup>®</sup> se utiliza para la adquisición de las señales sEMG para el posterior reconocimiento del movimiento individual de los dedos de la mano y los sensores flexibles son usados para etiquetar automáticamente la base de datos, la cual contiene los movimientos adquiridos con el dispositivo mencionado anteriormente.

## 2.2. PROTOCOLO EXPERIMENTAL

El protocolo que se va a presentar a continuación, tiene como objetivo explicar el procedimiento para adquirir señales sEMG en el antebrazo de sujetos voluntarios utilizando un prototipo de adquisición, con el fin de interpretar estas señales para encontrar la mayor correspondencia entre los electrodos y los movimientos individuales de los dedos.

La adquisición de las señales electromiográficas se realizó dentro del laboratorio Máquinas Inteligentes y Reconocimiento de Patrones ubicado en Parque-i (Sistema Integrado de laboratorios) del Instituto Tecnológico Metropolitano – ITM. El procedimiento tiene una duración de 15 minutos por cada sujeto, diez en las instrucciones y cinco en el proceso de la adquisición de las señales, se describen los pasos del procedimiento a continuación:

- **Información de la adquisición de datos:** Se le informa al sujeto sobre el proyecto en general en el cual va a participar, los procedimientos y los riesgos que se pueden generar durante la adquisición de datos.
- **Entrega del consentimiento informado:** Se le otorga al sujeto el consentimiento informado para que pueda tomar una decisión de participación. Comprendido el procedimiento que debe seguir para la adquisición de datos, los efectos secundarios y las molestias, el sujeto debe firmar la autorización en caso de aceptar.
  - **Efectos secundarios:** Es posible que los electrodos de superficie que contiene el dispositivo Myo Armband<sup>®</sup> puedan generar una reacción alérgica en la piel semejante a un enrojecimiento, estos efectos son menores y no se conocen a la fecha más efectos secundarios relacionados con los sensores y procedimientos a realizar.
  - **Molestias:** Al participar de este estudio es posible que se experimenten molestias menores, incomodidad y alguna presión mínima por el uso constante del brazalete MYO Armband<sup>®</sup> para la adquisición de señales del antebrazo, y en los dedos por las cintas velcro que ajustan los sensores flexibles.
- **Registro de los datos del sujeto:** Se obtiene información de la edad, sexo, peso y altura, para el control del registro de los sujetos pertenecientes a la base de datos.
- **Verificar condiciones iniciales para el procedimiento:** Se le pide a cada sujeto antes de comenzar con la adquisición, sentarse con ambos brazos apoyados sobre una mesa, de la manera más cómoda y sin distracciones que puedan perturbar su atención durante la ejecución de las tareas motoras.
- **Indicar al sujeto el procedimiento:** Se realiza un ejemplo con el sujeto donde se muestran los 6 movimientos y las 5 repeticiones que debe realizar por cada uno de los movimientos para la adquisición de los datos. Los movimientos son los siguientes:
  - Movimiento 1. Flexión del dedo pulgar
  - Movimiento 2. Flexión del dedo índice
  - Movimiento 3. Flexión del dedo medio
  - Movimiento 4. Flexión del dedo anular




Figura 2.1: Prototipo de Adquisición

- Movimiento 5. Flexión del dedo meñique
- Movimiento 6. Estado de reposo

Los movimientos de flexión de los dedos de la mano no se realizan con un orden consecutivo, es decir, de pulgar a meñique o de meñique a pulgar, esto con el fin de que el sujeto realice los movimientos de manera atenta y no por inercia, permitiendo realizar una buena adquisición. Por lo tanto, la flexión de los dedos se hace cuando se le indica al sujeto cuál dedo flexionar señalándole la punta del dedo seleccionado, luego se le cuentan las 5 repeticiones a medida que lo va flexionando, cuando termina las repeticiones del dedo seleccionado, el sujeto espera la indicación del siguiente dedo, y vuelve a realizar las 5 repeticiones con el dedo y así sucesivamente hasta terminar con todos los dedos de la mano, este registro sólo se realiza una vez por sujeto.

- **Ubicación del dispositivo e instrumento:**

Al sujeto se le ubican sensores flexibles en cada dedo de la mano y un dispositivo Myo Armband® en el antebrazo como se ilustra en la Figura 2.1.

- Sensor Flexible Modelo SEN0628 56mm: Cada sensor es ajustado uno a cada dedo de la mano mediante dos piezas, las cuales se diseñaron y se crearon en una impresora 3D– replicator 2x, marca Maker Bot, con el material Ácido poliláctico (PLA), y unas cintas velcro de 1.2 cm de ancho, ver Figura 2.1(a).
- Myo Armband®: Se sitúa el dispositivo MYO Armband® en la mano derecha del sujeto, asegurando que el canal cuatro esté en el antebrazo inferior seguido por el canal tres en sentido horario y el quinto canal en sentido anti horario, ver Figura 2.1(b).

- **Adquisición de señales electromiográficas de superficie:** Se registran las señales de electromiografía del sujeto cuando éste realiza los movimientos indicados anteriormente.

- **Finalización de la adquisición de señales electromiográficas:** Al culminar la adquisición de las señales de electromiografía superficial del sujeto, se retira el dispositivo MYO Armband® y los sensores flexibles.

## 2.3. ADQUISICIÓN BASE DE DATOS

Se adquirieron señales sEMG con el dispositivo Myo Armband® a 54 sujetos, 31 hombres y 23 mujeres entre 20-35 años de edad, sanos y voluntarios sin problemas motores o fisiológicos conocidos.

Para lograr un buen desempeño en términos de discriminación, en las etapas de extracción de características y clasificación se realiza un filtrado de las señales sEMG adquiridas, con el fin de minimizar los ruidos o artefactos de las señales sEMG provenientes de la red de distribución eléctrica (60Hz) y de fuentes del entorno como

los ruidos intrínsecos que resultan entre el contacto de la piel y el electrodo. Se utiliza un filtro rechazabanda Butterworth de orden 2 con una frecuencia de muestreo de 200Hz (frecuencia del dispositivo Myo Armband®), y una frecuencia de corte entre 58Hz y 62Hz. Además, la señal se filtra con un paso alta con una frecuencia de corte de 20Hz, debido a que las sEMG contienen información sobre las unidades motoras activas entre el rango de frecuencia de 2Hz a 500Hz [7–9].

La base de datos es etiquetada automáticamente mediante un pre-proceso y sacando provecho de la información entregada por 5 sensores flexibles Modelo SEN0628 56mm, que se sitúan uno en cada dedo de la mano, estos sensores permiten identificar a partir de la variación de la resistencia cuando éste se flexiona, donde su resistencia es inversamente proporcional a la flexión aplicada. Luego de adquirir las señales con los sensores flexibles, se realiza el pre-proceso de estas señales para el etiquetado de las señales sEMG, encontrando el segmento donde se realiza la actividad motora para identificar el movimiento realizado y enumerarlo según su clase. En la próxima sección se explica el pre-proceso y el etiquetado automático.

## 2.4. ETIQUETADO AUTOMÁTICO

La metodología utilizada para la etiquetación se representa en la Figura 2.2 y consta de cuatro etapas: filtrado, obtención de la energía de la señal, estimación de los puntos mínimos, e identificación del punto inicial y final de la actividad motora de la señal adquirida con los sensores flexibles. A continuación se hace la descripción de cada una de las etapas.

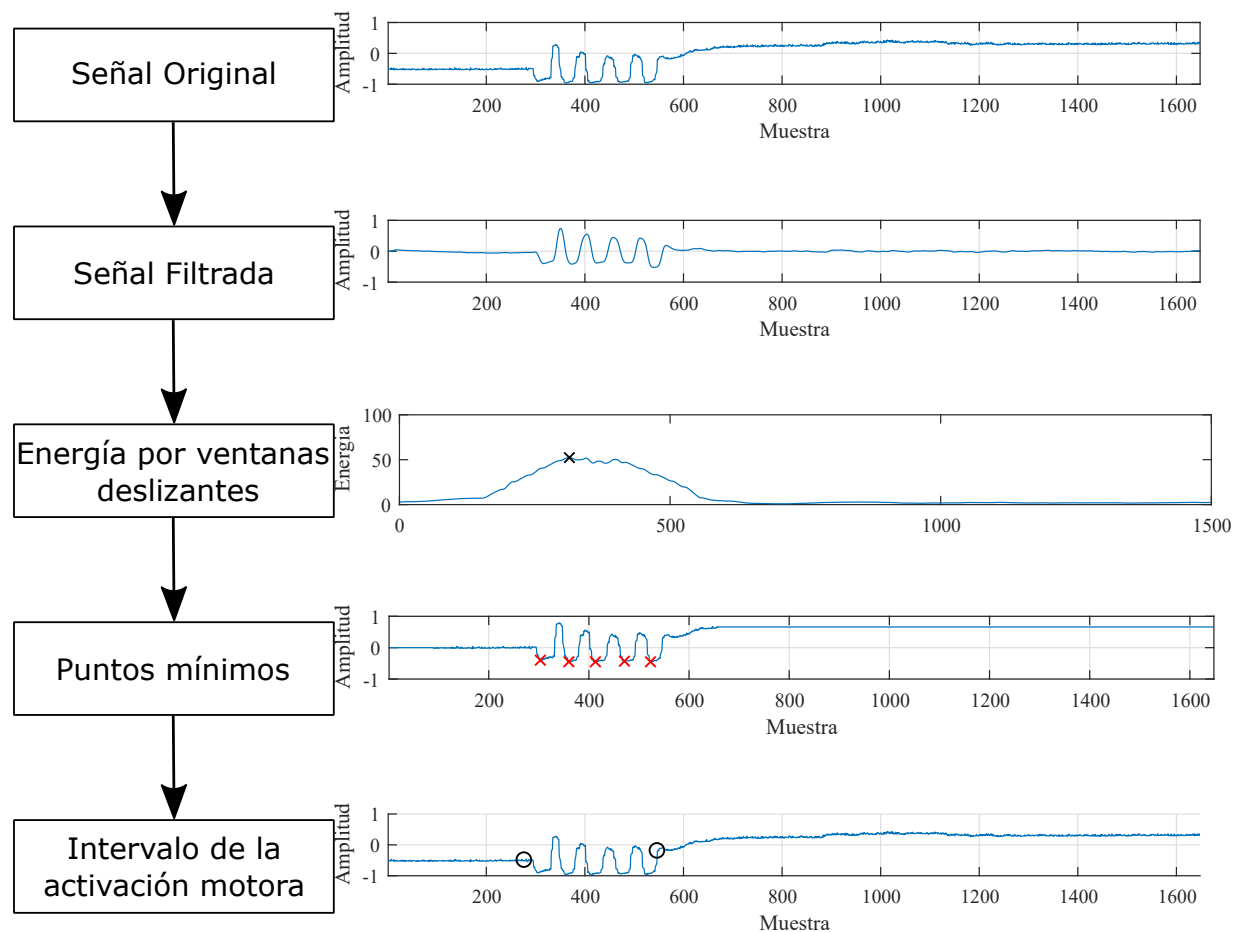




Figura 2.2: Diagrama de las etapas del etiquetado propuesto

Inicialmente, las señales adquiridas con los sensores flexibles son centralizadas restando la media para que todas queden sobre el mismo eje  $y = 0$ . Encontrar una actividad motora, es decir, las cinco repeticiones realiza-


das por cada movimiento como se indicó en el protocolo, se podría lograr encontrando los valores mínimos en la señal original, la cual contiene las cinco repeticiones claramente visibles sin otras activaciones producidas por los movimientos involuntarios, tal como se ilustra en la Figura 2.3(a), también se puede ver en las Figuras 2.3(b) y 2.3(c) que a pesar de que hay ruido se pueden identificar fácilmente las cinco repeticiones ya que tienen mayor amplitud que los segmentos de ruido en la señal. Sin embargo, en las señales originales se presentan diferentes casos que no permiten encontrar fácilmente la actividad motora. A continuación se describe cada uno.




(a) Sujeto 1, canal 9



(b) Sujeto 33, canal 13




(c) Sujeto 37, canal 11




(d) Sujeto 40, canal 10

Figura 2.3: Señal original con las cinco repeticiones claramente visibles


- **Caso 1.** En la señal se pueden observar diferentes actividades motoras, por lo general, son la que queremos identificar y otra involuntaria generada por el movimiento de otro dedo, ver Figura 2.4. En la Figura 2.4(a) y la Figura 2.4(b) se puede observar que hay dos activaciones motoras, cada una con sus 5 repeticiones, a diferencia de las figuras anteriores, la Figura 2.4(c) tiene las dos activaciones unidas.



(a) Sujeto 1, canal 12



(b) Sujeto 32, canal 10



(c) Sujeto 48, canal 12

Figura 2.4: Señales originales que presentan activaciones involuntarias

- **Caso 2.** En la señal se presenta la actividad motora con las cinco repeticiones y otra actividad involuntaria con valores inferiores a la de la actividad motora, ver Figura 2.5.

Por lo tanto, si encontramos en el *caso 1* los valores mínimos, se puede identificar el movimiento involuntario como la actividad motora, generando un error en la etiquetación. Asimismo, en el *caso 2* se podría identificar como actividad motora el movimiento involuntario porque éste puede tener los valores más pequeños que los de la actividad motora.

Para evitar que ruidos u otras activaciones involuntarias o reflejos se identifiquen como una actividad motora, y teniendo en cuenta que hay mayor energía cuando se realiza la actividad motora debido a los cinco movimientos consecutivos como se explica en el protocolo, se estiman las áreas bajo la curva (energía) mediante ventanas deslizantes de 150 puntos, luego se ubica el punto de mayor energía (pico), ver Figura 2.7(c), y a partir de ese punto el tamaño de la ventana se amplía 150% puntos del tamaño de la ventana usada por izquierda y por derecha, encontrando el intervalo de la actividad motora voluntaria.





Figura 2.5: Señales originales donde se presentan diferentes mínimos

En ocasiones las señales contienen una desviación de la línea de base (ruido), es decir, las señales contienen amplitudes diferentes debido a la naturaleza bipolar de la señal tal como se ilustra en la Figura 2.6, este ruido puede dañar el enfoque de la energía debido a que si se presenta mayor amplitud en la desviación de la señal u otro movimiento involuntario que en la señal de la activación motora, el ruido se puede identificar como el punto de mayor energía, presentando un inconveniente para encontrar la actividad motora. Con el fin de remover este ruido, se descompone la señal mediante EMD y se le restan los dos últimos IMFs y el residuo, ya que en ellos es donde se encuentran las bandas de frecuencia bajas [10–12], de tal manera que si en un segmento de la señal hay una activación motora con una amplitud inferior a la de ruido, movimientos involuntarios o desviación de la señal, éstas no se identifiquen como el punto de mayor energía. Luego, a la señal sin desviación de la línea de base se le encuentra la energía mediante ventanas deslizantes y el intervalo de la activación motora, tal como se explicó anteriormente.


Después en la señal original, ver Figura 2.7(a), los valores encontrados fuera del intervalo hallado a partir de energía se dejan constantes, por consiguiente, se encuentran los 5 valores mínimos consecutivos los cuales están resaltados en color rojo como se puede ver en la Figura 2.7(d), y luego se ubica la actividad motora encontrando el punto inicial con 15 puntos antes del primer valor mínimo y el final con 15 puntos después del último valor mínimo como se ilustra en la Figura 2.7(e), en esta figura el valor inicial está aproximadamente en 300 y el valor final en 550.




Para etiquetar la señal filtrada del Myo Armband<sup>®</sup>, el intervalo de activación hallado anteriormente se ubica en las señales adquiridas por éste y se le asigna la clase en la cual pertenece la actividad motora, como se puede ver en la Figura 2.8 tenemos las señales sEMG de un sujeto registradas por los 8 electrodos del dispositivo Myo Armband<sup>®</sup> etiquetadas cada uno con su clase (respectivo movimiento), estas etiquetas se encuentran clasificadas en franjas de señales con las cinco repeticiones de cada movimiento. El color amarillo pertenece a la clase o movimiento de reposo, el mostaza la flexión del meñique, verde flexión del dedo anular, cian flexión del dedo medio, azul flexión índice y por último, azul oscuro flexión del dedo pulgar.




(a) Sujeto 17, canal 9



(b) Sujeto 28, canal 12



(c) Sujeto 30, canal 13



(d) Sujeto 41, canal 9

Figura 2.6: Señales originales donde se presentan diferentes corrimientos de línea base

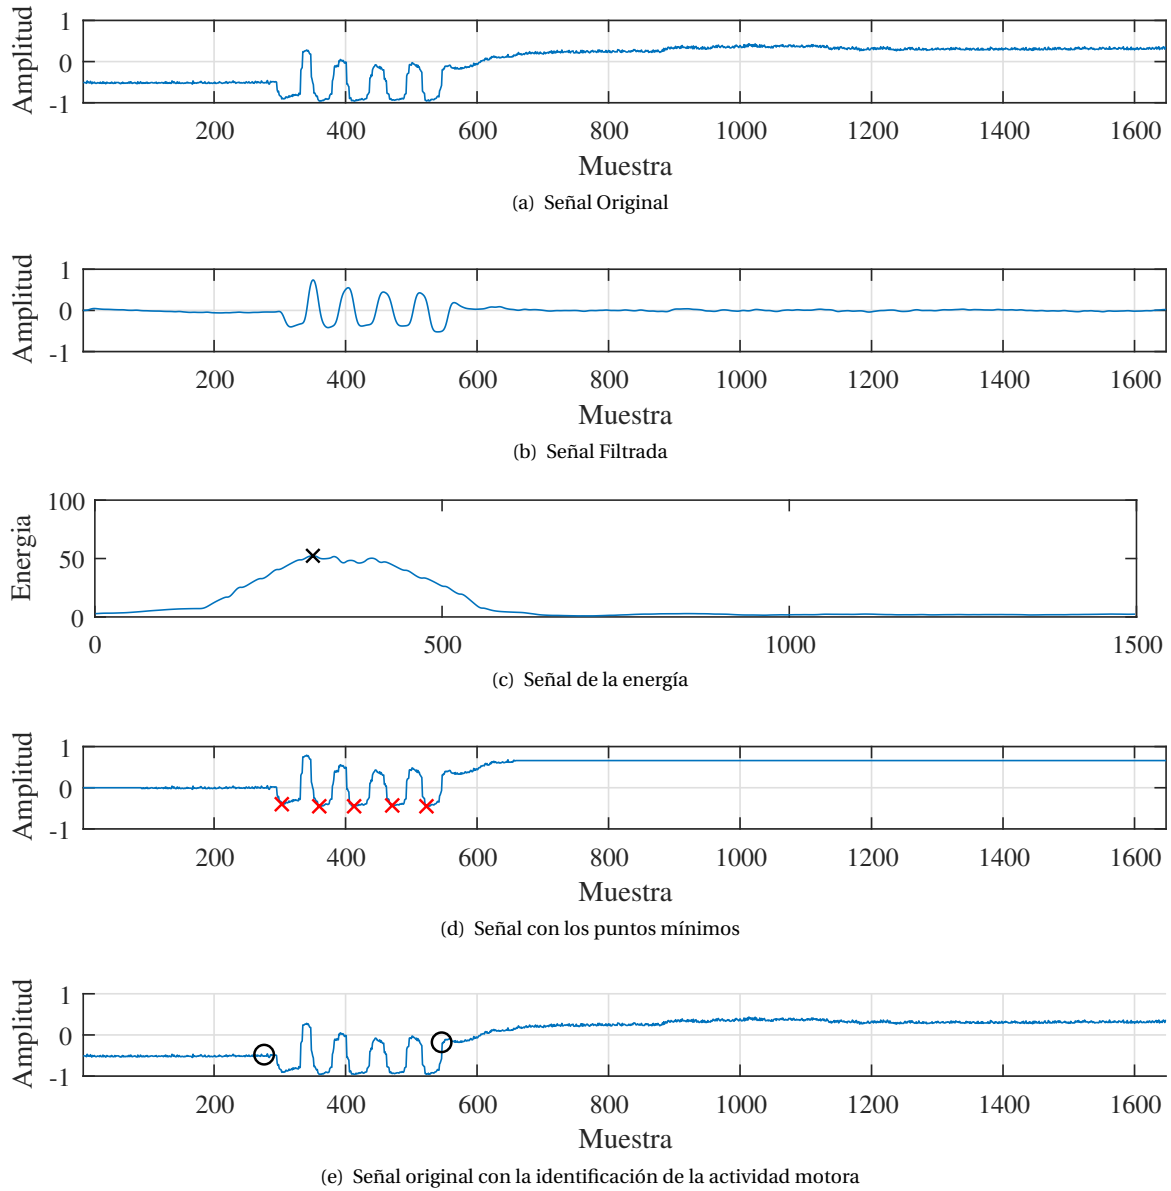


Figura 2.7: Proceso de identificación de la actividad motora voluntaria

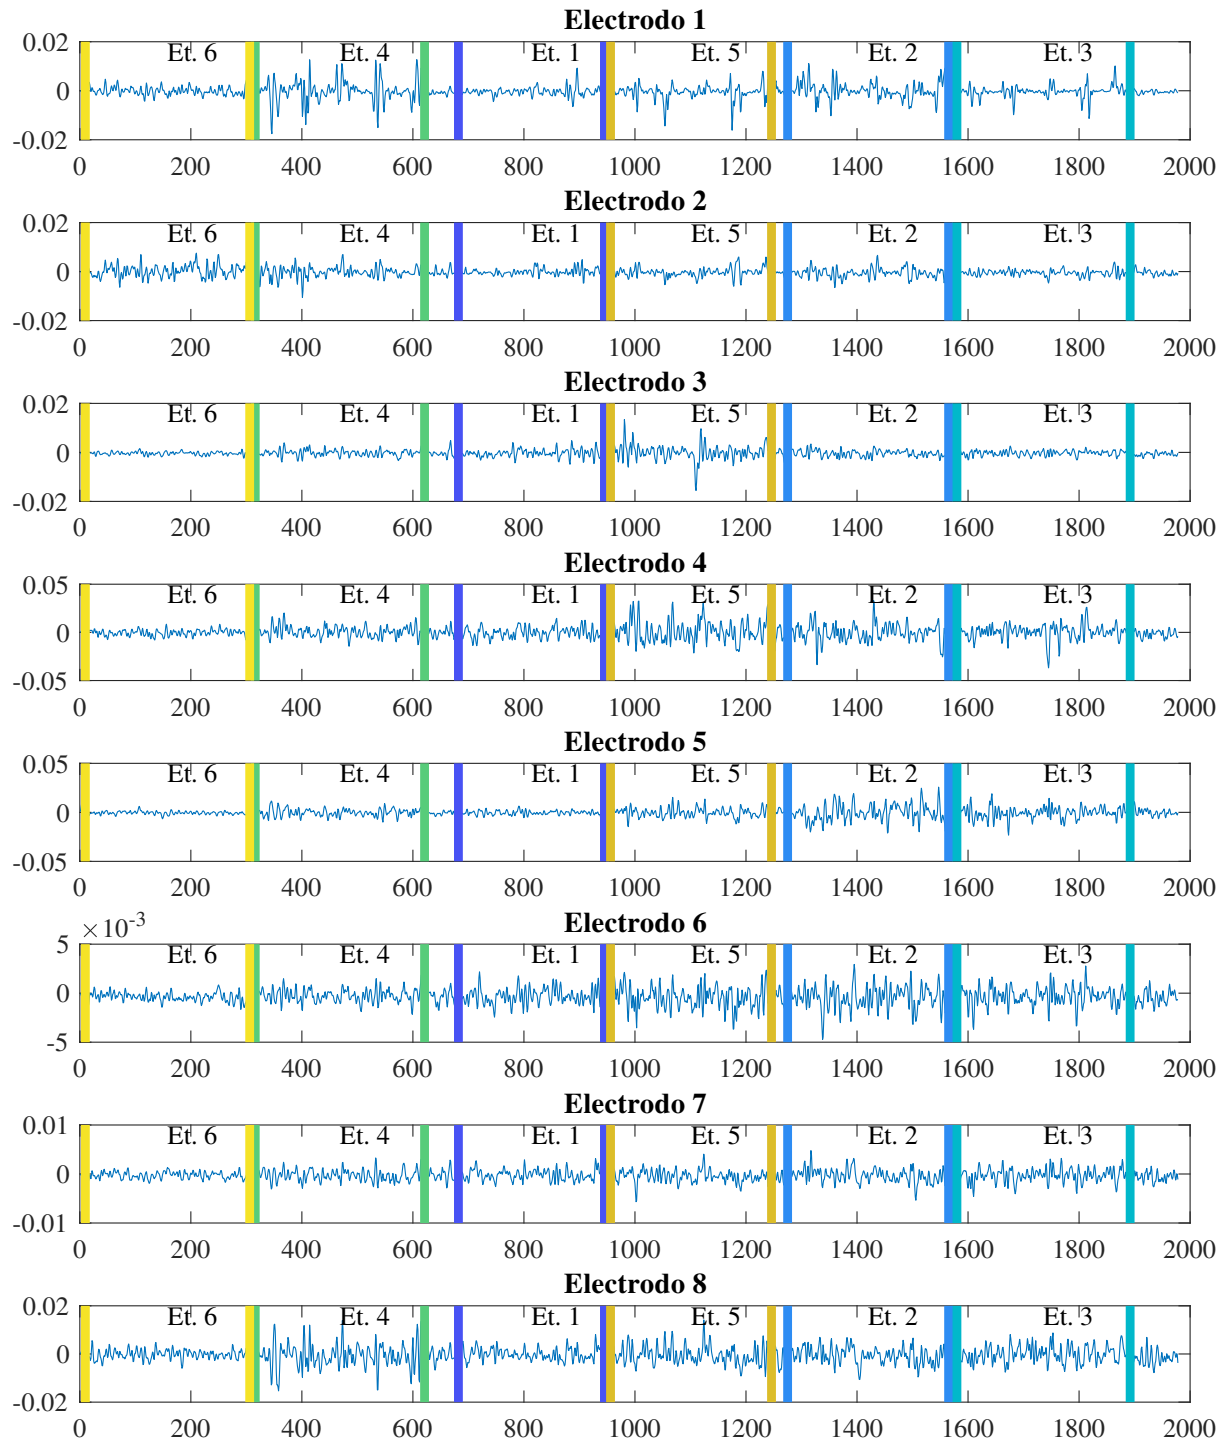


Figura 2.8: Señal sEMG etiquetada con la metodología propuesta

## REFERENCIAS

- [1] Y. Du, W. Jin, W. Wei, Y. Hu, and W. Geng, "Surface EMG-Based Inter-Session Gesture Recognition Enhanced by Deep Domain Adaptation," *Sensors*, vol. 17, no. 12, p. 458, feb 2017. [Online]. Available: <http://www.mdpi.com/1424-8220/17/3/458>
- [2] U. Côté-Allard, C. L. Fall, A. Drouin, A. Campeau-Lecours, C. Gosselin, K. Glette, F. Laviolette, and B. Gosselin, "Deep Learning for Electromyographic Hand Gesture Signal Classification by Leveraging Transfer Learning," jan 2018. [Online]. Available: <http://arxiv.org/abs/1801.07756>
- [3] C. Amma, T. Krings, J. Böer, and T. Schultz, "Advancing Muscle-Computer Interfaces with High-Density Electromyography," in *Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems - CHI '15*. New York, New York, USA: ACM Press, 2015, pp. 929–938. [Online]. Available: <http://dl.acm.org/citation.cfm?doid=2702123.2702501>
- [4] M. Atzori, A. Gijssberts, S. Heynen, A.-G. M. Hager, O. Deriaz, P. van der Smagt, C. Castellini, B. Caputo, and H. Muller, "Building the Ninapro database: A resource for the biorobotics community," in *2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics (BioRob)*. IEEE, jun 2012, pp. 1258–1265. [Online]. Available: <http://ieeexplore.ieee.org/document/6290287/>
- [5] A. Altamirano-Altamirano, G. Valentino-Orozco, A. Vera-Hernandez, and L. Leija-Salas, "Hand prosthesis with 5 DOF using embedded systems," in *2013 Pan Am. Heal. Care Exch.* IEEE, apr 2013, pp. 1–6. [Online]. Available: <http://ieeexplore.ieee.org/document/6568359/>
- [6] Thalmic Labs Inc., "Myo Armband," 2013. [Online]. Available: <https://www.myo.com/>
- [7] R. B. Northrop, *Non-invasive instrumentation and measurement in medical diagnosis*. CRC press, 2017.
- [8] D. Stegeman and H. Hermens, "Standards for surface electromyography: The european project surface emg for non-invasive assessment of muscles (seniam)," *Enschede: Roessingh Research and Development*, pp. 108–12, 2007.
- [9] P. Kieliba, P. Tropea, E. Pirondini, M. Coscia, S. Micera, and F. Artoni, "How are Muscle Synergies Affected by Electromyography Pre-Processing?" *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 26, no. 4, pp. 882–893, 2018.
- [10] M. Blanco-Velasco, B. Weng, and K. E. Barner, "ECG signal denoising and baseline wander correction based on the empirical mode decomposition," *Comput. Biol. Med.*, vol. 38, no. 1, pp. 1–13, jan 2008. [Online]. Available: <http://linkinghub.elsevier.com/retrieve/pii/S0010482507001114>
- [11] M. Ravanfar, L. Azinfar, R. Arefin, and R. Fazel-Rezai, "Electrocardiogram baseline wander removal based on empirical mode decomposition," in *Computing in Cardiology Conference (CinC), 2014*. IEEE, 2014, pp. 45–48.
- [12] X. Zhang and P. Zhou, "Filtering of surface EMG using ensemble empirical mode decomposition," *Med. Eng. Phys.*, vol. 35, no. 4, pp. 537–542, apr 2013. [Online]. Available: <http://linkinghub.elsevier.com/retrieve/pii/S135045331200286X>

# 3

## RECONOCIMIENTO DEL MOVIMIENTO

### Índice

---

<b>3.1 Generación de un espacio de representación</b> . . . . .	<b>31</b>
3.1.1 Selección de parámetros para la Transformada de Wavelet . . . . .	32
<b>3.2 Reducción de Características.</b> . . . . .	<b>35</b>
<b>3.3 Clasificación</b> . . . . .	<b>35</b>
<b>Referencias</b> . . . . .	<b>48</b>

---

### INTRODUCCIÓN

Para discriminar los movimientos de los dedos y los gestos de la mano, se han utilizado varios estimadores de características y clasificadores, las características más comunes son divididas en tres dominios: tiempo, frecuencia y el dominio de tiempo-frecuencia. El primer dominio incluye características como Valor Absoluto Medio (MAV), Longitud de Forma de Onda (WL), Cruces por Cero (ZC), Cambios de Signo de Pendiente (SSC), Amplitud de Willison (WAMP), entre otros [1–4]. En el segundo dominio, las características más utilizadas son Frecuencia Media (FMN), Frecuencia Mediana (FDM), Frecuencia Media Modificada (MFMN), Tasa de Frecuencia (FR), entre otros [5, 6]. Finalmente, en el dominio tiempo-frecuencia, la Transformada de Fourier de tiempo corto (STFT) y la Transformada de Wavelet Discreta (DWT) son las más utilizadas [7–9]. El aprendizaje supervisado emplea un conjunto de datos conocidos, llamado conjunto de entrenamiento, este conjunto está dividido en dos partes, primero datos de entrada (características) y segundo valores de respuestas (etiquetas). La finalidad es poder realizar predicciones mediante técnicas de clasificación tales como  $k$ -vecinos más cercanos ( $k$ -NN) [4, 10–12], Máquinas de Vectores de Soporte (SVM) [13–15] y aprendizaje profundo [16–18]. Si al conjunto de características se le extraen las más relevantes, el costo computacional y la complejidad se reduce, además, eliminar redundancias y características no relevantes generalmente mejora el desempeño de un clasificador [19, 20], por lo tanto, existen varios métodos para reducir la dimensión, entre los más utilizados están el análisis de componentes principales (PCA) y el análisis de componentes independientes (ICA), y los métodos de selección como selección secuencial hacia adelante, selección secuencial hacia atrás, entre otros [21]. En este capítulo se presenta la etapa de estimación de características y clasificación usando la base de datos etiquetada mencionada en el Capítulo 2, con el fin de reconocer el movimiento individual de los dedos de la mano.

### 3.1. GENERACIÓN DE UN ESPACIO DE REPRESENTACIÓN

Consiste en calcular la información representativa de las señales sEMG que producen un conjunto de características que reduce la dimensionalidad del problema de reconocimiento de patrones para la optimización del tiempo de cálculo. Las características se calcularon a partir de tres dominios: tiempo, frecuencia y tiempo-frecuencia, que están ampliamente documentados en la literatura [1–6]. Las características estimadas se resumen en la Tabla 3.1.

Tabla 3.1: Características estimadas a partir de señales sEMG. Para más información, ver [3]

Dominio del tiempo	Dominio de frecuencia	Dominio tiempo-frecuencia
Valor Integrado de EMG (IEMG)	Frecuencia Mediana (FMD)	Transformada Wavelet Discreta (DWT) [22]  <i>Características estimadas a partir de los coeficientes:</i> — Energía de Shannon — Energía de Teager — La energía cuadrada — Media — Varianza — Desviación estándar — Curtosis
Desviación estándar	Frecuencia media (FMN)	
Diferencia del Valor Absoluto de la Desviación Estándar (DASDV)	Modulación de Frecuencia Mediana (MFMD)	
Valor Medio Absoluto (MAV)		
Valor Absoluto Medio Modificado 1 (MMAV1)	Modulación de Frecuencia Media (MFMN)	
Valor Absoluto Medio Modificado 2 (MMAV2)		
Raíz media cuadrada (RMS)	Tasa de Frecuencia (FR)	
Varianza (VAR)		
Longitud de forma de onda (WL)	Relación señal/ruido (SNR)	
Cruce por cero (ZC)		
Cambios en la pendiente de la señal (SSC)	Frecuencia pico (PKF)	
Amplitud Willison (WAMP)		
Integral del cuadrado simple (SSI)	Potencia Media (MNP)	
Tasa de Porcentaje de Myopulse (MYOP)		

En la generación del espacio de representación, se obtuvo una matriz de características con 324 muestras (filas) o instancias y 720 características (columnas). Se estableció empíricamente tres veces el valor de la desviación estándar de la señal mediante búsqueda en rejilla, de 0.5 a 5 con pasos de 0.5, como el valor del umbral de las características del dominio de tiempo ZC, SSC, WA, MYOP.



### 3.1.1. SELECCIÓN DE PARÁMETROS PARA LA TRANSFORMADA DE WAVELET

En la literatura para realizar la estimación de características en el dominio tiempo-frecuencia se ha utilizado la transformada Wavelet con variedades de Wavelet madre y niveles de descomposición [8, 23–25], estos parámetros no están definidos como estándar para el reconocimiento de gestos y movimientos de los dedos de la mano, por lo tanto, en esta tesis se hace una experimentación con diferentes familias y niveles, con el fin de encontrar los parámetros más representativos en la descomposición Wavelet y generar un espacio de representación apropiado. Se utilizan las familias Daubechies con órdenes desde el 1 al 10, *coif1*, *coif4*, *coif5*, *bior2.2*, *bior4.4*, *bior5.5*, *rbio2.2* y por último, *sym5*, cada familia con 3, 4, 5, 6, 7 y 8 niveles de descomposición y las características estimadas a partir de los coeficientes son la energía de Shannon, energía de Teager, la energía cuadrada, media, varianza, desviación estándar y la curtosis [22].


Las características obtenidas con estas familias y niveles tienen una alta dimensionalidad, por lo tanto, se realiza una selección de características (SFS) y una extracción de características (PCA). Se utilizó SFS para reducir el número de dimensión al 30% del valor original y PCA también para reducir la dimensión reteniendo el 98% de la varianza [26], luego, para encontrar cuál es la mejor familia y nivel de descomposición, se hace una comparación con tres conjuntos de datos, el primero cuenta con las características estimadas a partir de los coeficientes mencionados anteriormente, el segundo con el conjunto de datos reducida con PCA y el tercer conjunto reducido con SFS. Se utiliza la media geométrica para evaluar el desempeño de los clasificadores  $k$ -NN, LDA y SVM en los tres conjuntos para encontrar los parámetros (Wavelet madre y niveles de descomposición) que mejor resultado brinden.

En la Figura 3.1 se pueden observar los resultados obtenidos para el conjunto de datos con las características estimadas a partir de los coeficientes Wavelet (energía de Shannon, energía de Teager, la energía cuadrada, media, varianza, desviación estándar y la curtosis), comparando las 18 familias, los niveles de descomposición del 3 al 8 y el desempeño con cada clasificador. En la Figura 3.1(a) las familias y el niveles con el mejor desem-

peño obtenido con el clasificador  $k$ -NN son bior 2.2 con 3 niveles de descomposición y bior 4.4 con niveles 6 y 7. Asimismo, se puede observar que el clasificador  $k$ -NN comparado con los demás (LDA y SVM), no tiene un buen desempeño en términos de la media geométrica, en la Figura 3.1(b) se obtuvo con el clasificador LDA la Wavelet madre db8 con el nivel 3, sin embargo, también hay otras familias que pueden seleccionarse porque tienen desempeños similares como db9 y sym5, con niveles 3 y 4, en la Figura 3.1(c) la Wavelet madre que mejor desempeño presenta es bior 2.2 con 7 niveles, en esta gráfica ocurre lo mismo que en las anteriores, hay otras familias que se pueden considerar como lo son el db9 y db6, con niveles 6, 7 y 8.

(a) Comparación de familias Wavelet vs desempeño  $k$ -NN

(b) Comparación de familias Wavelet vs desempeño LDA





(c) Comparación de familias Wavelet vs desempeño SVM

Figura 3.1: Comparación con el conjunto de datos con características estimadas a partir de los coeficientes de las familias Wavelet vs desempeño (media geométrica) con diferentes clasificadores y niveles de descomposición del 3 al 8


En la Figura 3.2 se hace la comparación de los resultados obtenidos para las 18 familias, niveles de descomposición, y clasificadores  $k$ -NN, LDA y SVM, con el conjunto de datos reducido con PCA. En la primera Figura 3.2(a) se observa que el mejor resultado con  $k$ -NN se obtiene con la Wavelet madre bior 2.2 y coif 4 con 4 y 3 niveles respectivamente, en la segunda Figura 3.2(b) con el clasificador LDA la Wavelet madre que presenta un buen desempeño en términos de la media geométrica es db8 y 8 niveles de descomposición, sin embargo, también hay otras Wavelet madre con desempeños similares como db9, bior 2.2, bior4.4 con niveles 6 y 8, en la tercera Figura 3.2(c) se puede ver que hay diferentes familias que pueden entregar un buen desempeño con el clasificador SVM como lo son db7, db8, coif1 y sym5 con 3 niveles de descomposición, sin embargo con la Wavelet madre db8 se puede observar en la gráfica que hay un bajo error.

En la Figura 3.3 se comparan los resultados alcanzados con las 18 familias, los niveles de descomposición del 3 al 8, y los clasificadores  $k$ -NN, LDA y SVM con el conjunto de datos reducido con SFS. Con el clasificador  $k$ -NN las Wavelet madre son coif1, bior 4.4, db8 con niveles 7 y 8. Con el clasificador LDA en la Figura 3.3(b) también



(a) Comparación de familias Wavelet vs desempeño  $k$ -NN

(b) Comparación de familias Wavelet vs desempeño LDA





(c) Comparación de familias Wavelet vs desempeño SVM


Figura 3.2: Comparación con el conjunto de datos reducido con PCA de las familias Wavelet vs desempeño con diferentes clasificadores y niveles de descomposición del 3 al 8

hay variedad, las Wavelet madre que alcanzan resultados más altos son db8, db9, coi1 y bior 4.4 con niveles 7 y 8, por último con el clasificador SVM los resultados presentados en la Figura 3.3(c), las familias con un mayor desempeño son db8, bior 4.4, coi5 y db9 con niveles 6, 7 y 8. Con este conjunto de datos se puede observar que en la Figura 3.3 se entrega el mejor desempeño con la media geométrica con respecto a los otros conjuntos, confirmando la necesidad de reducir la alta dimensión con el método SFS.

Como conclusión de la experimentación realizada, se puede confirmar lo revisado en la literatura, es decir, se utilizan una gran variedad de familias y niveles para realizar reconocimiento de los gestos y movimientos de los dedos de la mano, sin embargo, se puede observar en las figuras anteriormente mencionadas que hay familias que se repiten con las más altas medias geométricas en los diferentes conjuntos de datos, entre ellas están las Wavelet madre bior 2.2, bior 4.4, coi 5, db9 y db8 con los niveles que se destacan varias veces 6, 7 y 8. Desde el punto de vista del desempeño por cada clasificador, el  $k$ -NN tiene el menor desempeño de resultados en comparación con los demás clasificadores, por lo tanto, no es adecuado para definir los mejores parámetros para la transformada Wavelet discreta. También, basándose en los resultados obtenidos en términos de media geométrica, se puede deducir que realizando reducción con selección de características (SFS) se logran los mejores resultados de reconocimiento para LDA y SVM, en comparación con el conjunto reducido con PCA y el conjunto de datos sin reducción. A partir de lo anterior, para el desarrollo de los demás experimentos de esta tesis se seleccionó como Wavelet madre la db8 con 8 niveles de descomposición para la caracterización en tiempo-frecuencia con DWT de la base de datos adquirida, debido a que estos parámetros tienen un mejor desempeño y constancia en términos de media geométrica.

(a) Comparación de familias Wavelet vs desempeño  $k$ -NN

(b) Comparación de familias Wavelet vs desempeño LDA



(c) Comparación de familias Wavelet vs desempeño SVM

Figura 3.3: Comparación con el conjunto de datos reducido con SFS de las familias Wavelet vs desempeño con diferentes clasificadores y niveles de descomposición del 3 al 8

### 3.2. REDUCCIÓN DE CARACTERÍSTICAS

Se utilizó SFS y PCA para la etapa de reducción de características con el fin de seleccionar un subconjunto de características que proporcione la información más relevante de los movimientos de los dedos de la mano, evitando la redundancia entre ellas y eliminando las irrelevantes, reduciendo así la dimensionalidad del aprendizaje, problema que podría conducir a una reducción del tiempo computacional e incluso a mejorar el rendimiento de la clasificación. Finalmente, se obtuvo una matriz de 324 muestras (filas) o instancias y 720 características (columnas), que al reducirse con SFS se retienen 192 características y con PCA el valor depende de la retención de la varianza, en este caso, se buscó retener el 98% de la varianza total.

### 3.3. CLASIFICACIÓN

El proceso de clasificación tiene como objetivo identificar las etiquetas de las instancias en un conjunto de prueba (instancias desconocidas para el clasificador) sólo con base en las características obtenidas de las señales, es decir, el clasificador reúne las características de la señal sEMG y las asocia con una acción motora, en este caso para cada movimiento individual de los dedos de la mano, clase 1 (movimiento del dedo pulgar), clase 2 (movimiento del dedo índice), clase 3 (movimiento del dedo medio), clase 4 (movimiento del dedo anular), clase 5 (movimiento del dedo meñique) y por último clase 6 (estado de reposo). Se usaron clasificadores  $k$ -NN, SVM y LDA uno contra todos [27–29], y para evitar el sobreajuste de dichos modelos de clasificación, se realizó una validación cruzada con 10 iteraciones.

El clasificador  $k$ -NN se estableció con  $k$  igual a 1, 3, 5 y 7, se utilizó un kernel lineal para el clasificador SVM y se usó un valor  $C$  de 1. Los clasificadores y la técnica de selección de características se usaron con la herramientas de Balu [30]. Finalmente, para evaluar la precisión del rendimiento de la clasificación, se usaron medidas de exactitud, sensibilidad, especificidad y media geométrica.

Para determinar el mejor desempeño obtenido para el reconocimiento del movimiento individual de los dedos, se utilizaron los conjuntos de características tiempo (XT) con 120, frecuencia (XF) con 96 y tiempo-frecuencia (XTF) con 504, y se hizo con estos conjuntos una comparación evaluando de manera individual, con las posibles combinaciones entre los conjuntos y todas unidas en un sólo conjunto, además, se evaluó cada conjunto con todas las características, reducidas con PCA reteniendo los datos al 98% de la varianza y con SFS reduciendo el número de dimensión al 30%, tal como se observa en la Figura 3.4

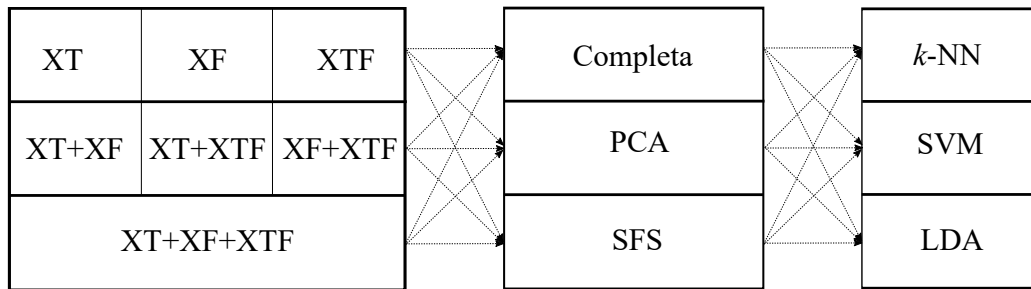






Figura 3.4: Experimentación con los conjuntos de características para evaluar el desempeño para el reconocimiento del movimiento individual de los dedos

En la Figura 3.5, se puede observar el desempeño del conjunto de características XT con el clasificador  $k$ -NN en cada clase, con  $k$  igual a 1, 3, 5 y 7. Analizando esta figura, podemos notar que con el valor de  $k = 1$  (ver Figura 3.5(a)), se tiene un mejor desempeño en comparación con los demás valores de  $k$ , tal como se puede observar en la Figura 3.5(b) y la Figura 3.5(c). Los valores de  $k$  iguales a 3 y 5, tienen un desempeño similar en exactitud (80%) y especificidad (90%) en cada clase, sin embargo, en sensibilidad y media geométrica varían con respecto a cada clase. Con el valor de  $k = 7$  los valores de desempeño en sensibilidad y media geométrica son casi cero en las clases 2 y 3, por lo tanto, podemos deducir que en la Figura 3.5(d) se demuestra que el clasificador con  $k$  igual a 7 no permite obtener un buen desempeño para el reconocimiento de los movimientos de los dedos.

En la Figura 3.6 se ilustra el desempeño del conjunto de características XF con el clasificador  $k$ -NN con los valores de  $k$  igual a 1 y 7. Con este conjunto de características ocurre lo mismo que con el de XT, en  $k$  igual a 7, ver Figura 3.6(b), el valor de la sensibilidad y media geométrica es casi cero, lo cual demuestra que este clasificador no discrimina la clase objetivo, y con el valor de  $k$  igual a 1, ver Figura 3.6(a), se cuenta con un mejor desempeño en comparación con los otros valores de  $k$  igual a 3, 5 y 7.

En la Figura 3.7 el conjunto de características XTF con el clasificador  $k$ -NN, no tiene mucha diferencia con los resultados obtenidos anteriormente (XT y XF), el valor de  $k$  que permite tener un mejor desempeño es uno en comparación con los valores de  $k$  igual a 3, 5 y 7, ver Figura 3.7(a), además el rendimiento con la sensibilidad y la media geométrica en algunas clases con el valor de  $k$  igual a 7 es cercano a cero, es decir, no es capaz de discriminar la clase objetivo (ver Figura 3.8(b)), en este caso, en la clase 1 y 2.

Utilizando para la medida de desempeño el clasificador  $k$ -NN y todas las características en un mismo conjunto (XT+XF+XTF), podemos observar que también tenemos el mismo problema con el valor de  $k$  igual a 7, ver Figura 3.8(b), en este caso la clase que no tiene un buen desempeño en sensibilidad y media geométrica es la clase 1 y 2. Con el valor de  $k$  igual a 1, en la Figura 3.8(a), se puede visualizar que tiene mejor resultado comparado con los demás valores de  $k$ , por lo tanto, se puede concluir que con el clasificador  $k$ -NN el número de vecinos 3, 5 y 7 no entregan un buen desempeño para la discriminación de la clase objetivo, debido a que en algunas clases el valor de la sensibilidad y media geométrica es casi cero, además, a pesar de que con  $k$  igual a 1 da mejores resultados, su valor es aproximadamente 15% en sensibilidad, y en media geométrica 25%, estos valores son muy bajos para el reconocimiento de los movimientos de los dedos de la mano. Lo mismo sucede con las posibles combinaciones en parejas entre los conjuntos XT, XF y XTF, los resultados son muy similares con el conjunto XT+XF+XTF.

(a) Desempeño con el clasificador  $k$ -NN,  $k=1$  en el conjunto de características XT(b) Desempeño con el clasificador  $k$ -NN,  $k=3$  en el conjunto de características XT(c) Desempeño con el clasificador  $k$ -NN,  $k=5$  en el conjunto de características XT(d) Desempeño con el clasificador  $k$ -NN,  $k=7$  en el conjunto de características XTFigura 3.5: Comparación con el conjunto de características XT y el clasificador  $k$ -NN




Figura 3.6: Comparación con el conjunto de características XF y el clasificador  $k$ -NN

También se analizaron los resultados de desempeño con los clasificadores LDA y SVM en cada conjunto de características. En la Figura 3.9 se muestran los resultados al comparar con el conjunto XT, observamos que en esta figura se obtiene un mejor desempeño con el clasificador SVM en comparación con el LDA, también es notable que los valores de exactitud, sensibilidad, especificidad y media geométrica son más estables y tiene mayor valor que con los del LDA, lo mismo sucede con el conjunto XF, ver Figura 3.10, el clasificador SVM entrega mejores resultados que con el LDA, ver Figura 3.10(a) y Figura 3.10(b). A diferencia de estos dos conjuntos (XT y XF), en el conjunto de características XTF, ver Figura 3.11, sucede lo contrario, se tienen los valores más estables con el clasificador LDA que con el SVM, ver Figura 3.11(a) y Figura 3.11(b).

Depués de realizar la comparación con cada conjunto, se estudia también el desempeño de los clasificadores SVM y LDA con los conjuntos de las posibles combinaciones en parejas entre las características XT, XF y XTF, y todas unidas en un mismo conjunto (XT+XF+XTF), tal como se muestran en la Figura 3.12 y la Figura 3.13. En la primer figura, el conjunto de combinación que mejor desempeño entrega es el conjunto XT+XF+XTF con un valor del 55%, ver Figura 3.12(d), no obstante, en las Figuras 3.12(a), 3.12(b), 3.12(c) las combinaciones parejas de conjuntos de características no contienen un buen desempeño en sensibilidad y media geométrica, obteniendo valores casi cero en las clases 1, 2 y 6.

En la Figura 3.13, se percibe que el conjunto de características con el conjunto XT+XF+XTF con el clasificador SVM tiene un desempeño inferior a usar las parejas de conjuntos de características. En las Figuras 3.13(a), 3.13(b), 3.13(c), se observa que tienen una similitud de desempeño en las medidas de exactitud, sensibilidad, especificidad y media geométrica, en cambio con la Figura 3.13(d), se puede observar que hay una variación con respecto a las demás.

Para el conjunto con las características reducidas con PCA y con SFS, únicamente se analiza el desempeño con el conjunto con todas las características (XT+XF+XTF) y los clasificadores LDA y SVM, esto debido a que con el clasificador  $k$ -NN, SVM y LDA los valores son similares a los encontrados en el conjunto de características






Figura 3.7: Comparación con el conjunto de características XTF y el clasificador  $k$ -NN

tanto individuales como la de las posibles combinaciones por parejas, es decir, que con el valor de  $k$  igual a 1 se tienen mejores resultados que con los demás valores 3, 5 y 7 y con respecto al clasificador LDA las clases 1, 2 y 6 el valor de sensibilidad y media geométrica es casi cero y con el clasificador SVM los valores están alrededor del 68% siendo mejor que el LDA.

En la Figura 3.14 se ilustran los resultados obtenidos con el clasificador LDA con el conjunto con todas las características (XT+XF+XTF) reducidas con PCA. La Figura 3.14(a) no tiene un buen desempeño en sensibilidad y media geométrica, incluso en algunas clases como la 1, 2 y 3 es casi el valor de cero, lo contrario sucede en la Figura 3.14(b), podemos decir con los resultados obtenidos en las diferentes medidas de desempeño, que el clasificador LDA con el conjunto de características XT+XF+XTF reducida con PCA es mejor comparado con el clasificador SVM.

En la Figura 3.15 se evalúa el desempeño con el conjunto de características reducidas con la técnica de selección SFS y los clasificadores SVM y LDA. En la Figura 3.15(a) y 3.15(b), podemos observar que también el clasificador LDA tiene un mejor rendimiento con respecto al SVM, el LDA tiene un valor medio aproximado de 98% y el clasificador SVM 95%.

Se concluye que el mejor clasificador es el LDA con un desempeño de 98% para la discriminación de todas las clases, el SVM también obtiene un buen desempeño, sin embargo, a comparación del LDA tiene menor resultado (95%). A diferencia de los clasificadores anteriores, el  $k$ -NN no entrega un buen desempeño para la discriminación de las clases, debido a que en algunas de ellas el valor de la sensibilidad y media geométrica es casi cero, indicando que no le es posible identificar la clase objetivo de manera apropiada. Por otro lado, también es notable, que los clasificadores obtienen mejor desempeño cuando se utiliza el conjunto con todas las características, es decir, con los tres dominios (tiempo, frecuencia y tiempo-frecuencia), y además se comprobó que se requiere de una reducción de características para obtener un mejor reconocimiento de los movimientos individuales de los dedos de la mano, en este caso el selector SFS. Como SFS minimiza una función relacionada

(a) Desempeño con el clasificador  $k$ -NN,  $k=1$  con todo el conjunto de características XT+XF+XTF(b) Desempeño con el clasificador  $k$ -NN,  $k=7$  con todo el conjunto de características XT+XF+XTFFigura 3.8: Comparación con todo el conjunto de características XT+XF+XTF y el clasificador  $k$ -NN

con la medida de fisher y LDA también está basada en esa misma medida, el selector SFS beneficia al clasificador LDA, obteniendo el mejor desempeño para el reconocimiento. Para ver los resultados principales de lo mencionado anteriormente, revisar la la Tabla 3.2, donde se analizó todas las clases con el conjunto de todas las características (XT+XF+XTF), el valor de  $k=1$  y en términos de la medida de desempeño media geométrica, ésta última, debido a que está relacionada con las demás medidas de desempeño (sensibilidad, especificidad).

Las clases 1, 2 y 3 en los experimentos realizados con los clasificadores son las que menor discriminación presentaron, ya que el dedo pulgar (clase 1) es diferente a los demás dedos, debido a que el número de falanges se reducen a dos y la articulación metacarpofalángica es menos móvil que los otros dedos, por otro lado, cuando se flexiona con intención un dedo es ayudado por los otros que han puesto una tensión al extenderse o flexionarse en los músculos poliarticulares que intervienen así en la flexión del dedo probado [31], por lo tanto, los dedos índice y medio en los experimentos fueron más tensionados los músculos que el anular y el meñique, teniendo en cuenta también que el dedo meñique tiene un extensor propio.





Figura 3.9: Comparación con el conjunto de características XT y el clasificador LDA y SVM


Tabla 3.2: Resultados principales (con el conjunto de características XT+XF+XTE, con  $k=1$  y con la medida de desempeño media geométrica) para el reconocimiento del movimiento individual de los dedos de la mano

Clase	Base de datos	% $k$ -NN	% SVM	% LDA
1	Completa	27.51 ± 19.06	26.08 ± 18.7	42.71 ± 8.31
	PCA	39.32 ± 17.32	53.72 ± 12.82	0 ± 0
	SFS	44.88 ± 28.3	89.58 ± 11.02	97.07 ± 3.95
2	Completa	18.52 ± 24.69	37.31 ± 23.53	47.75 ± 11.99
	PCA	20.22 ± 27.58	46.78 ± 10.73	0 ± 0
	SFS	19.6 ± 20.73	98.85 ± 1.9	99.63 ± 0.79
3	Completa	22.79 ± 25.05	42.4 ± 16.6	47.65 ± 10.46
	PCA	30.49 ± 27.96	58.95 ± 8.36	4.39 ± 13.88
	SFS	32 ± 25.83	95.39 ± 5.42	99.43 ± 0.91
4	Completa	53.38 ± 23.3	66.18 ± 9.89	55.39 ± 9.43
	PCA	66.07 ± 15.21	71.78 ± 14.54	54.75 ± 11.24
	SFS	54.32 ± 22.11	98.76 ± 3.33	100 ± 0
5	Completa	42.95 ± 16.81	55.74 ± 15.7	49.19 ± 20.18
	PCA	48.5 ± 29.01	59.64 ± 13.21	32.67 ± 29.69
	SFS	38.15 ± 22.1	96.65 ± 5.06	99.13 ± 2.76
6	Completa	59.22 ± 15.1	63.32 ± 13.83	53.19 ± 15.59
	PCA	50.7 ± 21.78	66.62 ± 9.65	0 ± 0
	SFS	36.59 ± 28.65	98.68 ± 1.55	98.75 ± 2.74






(a) Desempeño con el clasificador LDA en el conjunto de características XF




(b) Desempeño con el clasificador SVM en el conjunto de características XF

Figura 3.10: Comparación con el conjunto de características XF y el clasificador LDA y SVM




(a) Desempeño con el clasificador LDA en el conjunto de características XTF




(b) Desempeño con el clasificador SVM en el conjunto de características XTF


Figura 3.11: Comparación con el conjunto de características XTF y el clasificador LDA y SVM




(a) Desempeño con el clasificador LDA con la combinación de los conjuntos de características XT+XF



(b) Desempeño con el clasificador LDA con la combinación de los conjuntos de características XT+XTF




(c) Desempeño con el clasificador LDA con la combinación de los conjuntos de características XF+XTF




(d) Desempeño con el clasificador LDA con todos los conjuntos de características XT+XF+XTF


Figura 3.12: Comparación con el conjunto de combinaciones de características y el clasificador LDA




(a) Desempeño con el clasificador SVM con la combinación de los conjuntos de características XT+XF



(b) Desempeño con el clasificador SVM con la combinación de los conjuntos de características XT+XTF




(c) Desempeño con el clasificador SVM con la combinación de los conjuntos de características XF+XTF




(d) Desempeño con el clasificador SVM con todos los conjuntos de características XT+XF+XTF

Figura 3.13: Comparación con el conjunto de combinaciones de características y el clasificador SVM



(a) Desempeño con el clasificador LDA con el conjunto de características XT+XF+XTF reducidas con PCA



(b) Desempeño con el clasificador SVM con el conjunto de características XT+XF+XTF reducidas con PCA

Figura 3.14: Desempeño con los clasificadores SVM y LDA con el conjunto de características XT+XF+XTF reducidas con PCA




Figura 3.15: Desempeño con los clasificadores SVM y LDA con el conjunto de características XT+XF+XTF reducidas con SFS

## REFERENCIAS

- [1] M. C. Tosin, M. Majolo, R. Chedid, V. H. Cene, and A. Balbinot, "sEMG feature selection and classification using SVM-RFE," in *2017 39th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.* IEEE, jul 2017, pp. 390–393.
- [2] F. Bian, R. Li, and P. Liang, "SVM based simultaneous hand movements classification using sEMG signals," in *2017 IEEE Int. Conf. Mechatronics Autom.* IEEE, 2017, pp. 427–432.
- [3] A. Phinyomark and E. Scheme, "A feature extraction issue for myoelectric control based on wearable EMG sensors," in *2018 IEEE Sensors Appl. Symp.* IEEE, mar 2018, pp. 1–6.
- [4] W.-T. Shi, Z.-J. Lyu, S.-T. Tang, T.-L. Chia, and C.-Y. Yang, "A bionic hand controlled by hand gesture recognition based on surface EMG signals: A preliminary study," *Biocybern. Biomed. Eng.*, vol. 38, no. 1, pp. 126–135, 2018.
- [5] A. Oleinikov, B. Abibullaev, A. Shintemirov, and M. Folgheraiter, "Feature extraction and real-time recognition of hand motion intentions from EMGs via artificial neural networks," in *2018 6th Int. Conf. Brain-Computer Interface.* IEEE, 2018, pp. 1–5.
- [6] Y. Wu, S. Liang, L. Zhang, Z. Chai, C. Cao, and S. Wang, "Gesture recognition method based on a single-channel sEMG envelope signal," *EURASIP J. Wirel. Commun. Netw.*, vol. 2018, no. 1, p. 35, 2018.
- [7] G. R. Naik, *Applications, Challenges, and Advancements in Electromyography Signal Processing*, ser. Advances in Medical Technologies and Clinical Practice, G. R. Naik, Ed. IGI Global, 2014.
- [8] F. Duan, L. Dai, W. Chang, Z. Chen, C. Zhu, and W. Li, "sEMG-Based Identification of Hand Motion Commands Using Wavelet Neural Network Combined With Discrete Wavelet Transform," *IEEE Trans. Ind. Electron.*, vol. 63, no. 3, pp. 1923–1934, mar 2016.
- [9] A. Phinyomark, F. Quaine, S. Charbonnier, C. Serviere, F. Tarpin-Bernard, and Y. Laurillau, "EMG feature evaluation for improving myoelectric pattern recognition robustness," *Expert Syst. Appl.*, vol. 40, no. 12, pp. 4832–4840, sep 2013.
- [10] G. Purushothaman and R. Vikas, "Identification of a feature selection based pattern recognition scheme for finger movement recognition from multichannel EMG signals," *Australas. Phys. Eng. Sci. Med.*, vol. 41, no. 2, pp. 549–559, jun 2018.
- [11] J. Kim, S. Mastnik, and E. André, "EMG-based hand gesture recognition for realtime biosignal interfacing," in *Proc. 13th Int. Conf. Intell. user interfaces - IUI '08.* New York, New York, USA: ACM Press, 2008, p. 30. [Online]. Available: <http://portal.acm.org/citation.cfm?doid=1378773.1378778>
- [12] Y. Liu, X. Wang, and K. Yan, "Hand gesture recognition based on concentric circular scan lines and weighted K-nearest neighbor algorithm," *Multimed. Tools Appl.*, vol. 77, no. 1, pp. 209–223, jan 2018. [Online]. Available: <http://link.springer.com/10.1007/s11042-016-4265-6>
- [13] X. Hu, J. Kan, and W. Li, "Classification of surface electromyogram signals based on directed acyclic graphs and support vector machines," *TURKISH J. Electr. Eng. Comput. Sci.*, vol. 26, no. 2, pp. 732–742, mar 2018.
- [14] W.-J. Li, C.-Y. Hsieh, L.-F. Lin, and W.-C. Chu, "Hand gesture recognition for post-stroke rehabilitation using leap motion," in *2017 Int. Conf. Appl. Syst. Innov.* IEEE, may 2017, pp. 386–388. [Online]. Available: <http://ieeexplore.ieee.org/document/7988433/>
- [15] N. Siddiqui and R. H. M. Chan, "A wearable hand gesture recognition device based on acoustic measurements at wrist," in *2017 39th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.* IEEE, jul 2017, pp. 4443–4446. [Online]. Available: <https://ieeexplore.ieee.org/document/8037842/>
- [16] Y. Du, W. Jin, W. Wei, Y. Hu, and W. Geng, "Surface emg-based inter-session gesture recognition enhanced by deep domain adaptation," *Sensors*, vol. 17, no. 3, p. 458, 2017.

- [17] K. Xing, Z. Ding, S. Jiang, X. Ma, K. Yang, C. Yang, X. Li, and F. Jiang, "Hand Gesture Recognition Based on Deep Learning Method," in *2018 IEEE Third Int. Conf. Data Sci. Cybersp.* IEEE, jun 2018, pp. 542–546. [Online]. Available: <https://ieeexplore.ieee.org/document/8411908/>
- [18] O. K. Oyedotun and A. Khashman, "Deep learning in vision-based static hand gesture recognition," *Neural Comput. Appl.*, vol. 28, no. 12, pp. 3941–3951, dec 2017. [Online]. Available: <http://link.springer.com/10.1007/s00521-016-2294-8>
- [19] C. Li, J. Ren, H. Huang, B. Wang, Y. Zhu, and H. Hu, "PCA and deep learning based myoelectric grasping control of a prosthetic hand," *Biomed. Eng. Online*, vol. 17, no. 1, p. 107, dec 2018. [Online]. Available: <https://biomedical-engineering-online.biomedcentral.com/articles/10.1186/s12938-018-0539-8>
- [20] "Clasificación en dos etapas de los gestos con las manos utilizando un electromiograma de superficie," in *2018 Quinta Conferencia Internacional sobre Procesamiento de Señales y Redes Integradas (SPIN)*.
- [21] G. Chandrashekar and F. Sahin, "A survey on feature selection methods," *Comput. Electr. Eng.*, vol. 40, no. 1, pp. 16–28, 2014.
- [22] M. Vallejo, C. J. Gallego, L. Duque-Muñoz, and E. Delgado-Trejos, "Neuromuscular disease detection by neural networks and fuzzy entropy on time-frequency analysis of electromyography signals," *Expert Systems*, p. e12274, mar 2018.
- [23] M. Hakonen, H. Piitulainen, and A. Visala, "Current state of digital signal processing in myoelectric interfaces and related applications," *Biomed. Signal Process. Control*, vol. 18, pp. 334–359, apr 2015.
- [24] S. Pizzolato, L. Tagliapietra, M. Cognolato, M. Reggiani, H. Müller, and M. Atzori, "Comparison of six electromyography acquisition setups on hand movement classification tasks," *PLoS One*, vol. 12, no. 10, p. e0186132, oct 2017.
- [25] M. Atzori, A. Gijssberts, C. Castellini, B. Caputo, A.-G. M. Hager, S. Elsig, G. Giatsidis, F. Bassetto, and H. Müller, "Electromyography data for non-invasive naturally-controlled robotic hand prostheses," *Sci. Data*, vol. 1, p. 140053, dec 2014.
- [26] L. Vega-Escobar, A. Castro-Ospina, and L. Duque-Muñoz, "Feature extraction schemes for bci systems," in *Signal Processing, Images and Computer Vision (STSIVA), 2015 20th Symposium on.* IEEE, 2015, pp. 1–6.
- [27] R. N. Khushaba, S. Kodagoda, M. Takruri, and G. Dissanayake, "Toward improved control of prosthetic fingers using surface electromyogram (emg) signals," *Expert Systems with Applications*, vol. 39, no. 12, pp. 10 731–10 738, 2012.
- [28] K. Anam and A. Al-Jumaily, "Optimized kernel extreme learning machine for myoelectric pattern recognition," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 8, no. 1, pp. 483–496, 2018.
- [29] N. y. T. M. I. y. A. M. W. Javaid, Haider Ali y Rashid, "Análisis comparativo de las características de la señal emg en dominio de tiempo y dominio de frecuencia usando myo gesture control," in *Actas de la 4 ° Conferencia Internacional 2018 sobre Mecatrónica y Robótica Ingeniería*.
- [30] D. Mery, "BALU: A Matlab toolbox for computer vision, pattern recognition and image processing (<http://dmery.ing.puc.cl/index.php/balu>)," 2011.
- [31] A. Leroy, C. Génot, H. Neiger, M. Dufour, G. Péninou, and J. Dupré, *Kinesioterapia*. Ed. Médica Panamericana, 2000, vol. 2.



# 4

## CONCLUSIONES Y TRABAJO FUTURO

Se propuso una metodología basada en el entrenamiento automático para el reconocimiento del movimiento individual de los dedos de la mano a partir del análisis de una base de datos adquirida mediante un brazalete de electrodos, utilizando técnicas de estimación de características en los dominios de tiempo, frecuencia y tiempo-frecuencia, y se realizó una combinación en parejas entre ellas y con todos los conjuntos para obtener el mejor conjunto de características, concluyendo que para obtener un mejor rendimiento en la discriminación se requiere del conjunto con todos los dominios, resaltando la importancia de la generación de estos espacios de representación. Además, se hizo una selección de características empleando el selector de características SFS buscando mejorar el desempeño de los clasificadores usados. Como clasificadores, se tuvieron en cuenta los más comunes para este tipo de tareas, a saber,  $k$ -NN, SVM y LDA uno contra todos. Los resultados obtenidos muestran que el rendimiento de la metodología propuesta es del 95% para todas las clases con el clasificador SVM, para LDA es 98%, mientras que con  $k$ -NN alcanza el 37%, por lo tanto, el  $k$ -NN no es adecuado para reconocer los movimientos individuales de los dedos de la mano con la metodología propuesta.

El protocolo experimental diseñado con el sensor Myo Armband<sup>®</sup> y el procesamiento de la señal fue satisfactorio, fue cómodo para los sujetos y las señales registradas contenían pocos artefactos, demostrando que estas nuevas tecnologías interactivas, a pesar de la limitación de sólo utilizarse en extremidades superiores, permiten realizar reconocimiento de los dedos de la mano con un buen desempeño. Además, se propuso una etiquetación automática lo que hace que no se requiera de una re-etiquetación, permitiendo tener control sobre cada movimiento realizado por el sujeto y asegurar que cada etiqueta sea acorde a cada clase y mejorando la efectividad y calidad de los resultados de los clasificadores.

Por otro lado, se confirma que para la transformada Wavelet Discreta hay una variedad de familias y niveles de descomposición que permiten realizar reconocimiento de los gestos y movimientos de los dedos de la mano, sin embargo, con la Wavelet madre db8 con 8 niveles de descomposición se obtiene un mejor desempeño en comparación de los demás parámetros experimentados, según el análisis exhaustivo realizado con 18 familias y 6 niveles de descomposición.

El clasificador  $k$ -NN no discrimina algunas clases, debido a que la sensibilidad y media geométrica en la clase objetivo es cercana a cero, lo cual demuestra que este clasificador no es apropiado para el reconocimiento del movimiento individual de los dedos. A diferencia del  $k$ -NN, los clasificadores SVM y LDA obtienen mejores resultados, siendo éste último el mejor de todos.

El dedo pulgar (clase 1) obtuvo menor desempeño porque contiene únicamente dos falanges y la articulación metacarpofalángica es menos móvil que los otros dedos, los dedos índice (clase 2) y medio (clase 3) también obtuvieron menos desempeño en comparación con el dedo anular (clase 4) y meñique (clase 5), ya que los músculos en estos dedos fueron más tensionados, sin embargo, se obtuvo en general un desempeño de reconocimiento de 98%, por lo tanto, es posible reconocer gestos con la combinación de aducción-abducción y flexión-extensión de los dedos.

Como trabajo futuro, sería interesante incluir en el sistema de adquisición los otros sensores integrados en el dispositivo Myo Armband<sup>®</sup> (acelerómetro, magnetómetro y giroscopio), para estudiar si esta información

podría mejorar el rendimiento logrado con nuestra metodología, también hacer selección de electrodos para encontrar la mínima cantidad para realizar el reconocimiento. Extender el número de sujetos en la base de datos, con el fin de poder utilizar técnicas de aprendizaje que requieren más datos como el aprendizaje profundo. También sería interesante realizar la comparación de representaciones (conjuntos de características) y clasificadores con alguna prueba de hipótesis para confirmar si las diferencias observadas son estadísticamente significativas y adaptar la metodología para realizar un reconocimiento en tiempo real, utilizar clasificadores multiclase y probar el reconocimiento de los movimientos en un exoesqueleto o un brazo robótico.