



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS



INSTITUTO DE INVESTIGACIÓN EN CIENCIAS BÁSICAS Y APLICADAS (IICBA)

**CENTRO DE INVESTIGACIÓN EN INGENIERÍA Y CIENCIAS APLICADAS
(CIICAp)**

**Diseño e implementación de una metodología para la
adquisición, clasificación e interpretación de señales
electromiográficas para personas con algún tipo de
discapacidad o amputación de mano**

TESIS

**QUE PARA OBTENER EL GRADO DE
DOCTOR EN INGENIERÍA Y CIENCIAS APLICADAS**

PRESENTA

MICA. JORGE ARTURO SANDOVAL ESPINO

DIRECTOR: DR. ALVARO ZAMUDIO LARA

CO DIRECTOR: DR. JOSÉ ANTONIO MARBÁN SALGADO

CUERNAVACA, MORELOS, OCTUBRE DEL 2023

Resumen

El propósito de este trabajo es establecer una metodología para adquirir, clasificar e interpretar señales electromiográficas en personas con discapacidades o amputaciones de mano, con el objetivo de desarrollar un modelo de clasificación óptimo para aplicaciones de prótesis de mano electromecánica o rehabilitación de amputados. Nuestro enfoque se basó en una base de datos pública que contenía señales mioeléctricas de 50 movimientos diferentes de 40 individuos sanos y 11 amputados.

Para lograrlo, empleamos cuatro conjuntos de características en el dominio del tiempo (TD) y dos estructuras de redes neuronales profundas (Deep Learning): una Red Neuronal Artificial (ANN) y una Red Neuronal Convolucional (CNN). Estas redes se eligieron debido a su desempeño probado en la literatura. Dado que nuestra aplicación involucra la toma de decisiones en intervalos cortos de tiempo, trabajamos con dos segmentaciones de ventana diferentes, de 200 ms y 150 ms respectivamente. Además, en el caso de las redes CNN, introdujimos una variable adicional: la forma de estructurar las imágenes para crear la base de datos de entrenamiento y validación. Exploramos cuatro tipos de imágenes, uno de los cuales fue propuesto por nosotros por primera vez en la literatura.

Para evaluar los resultados, consideramos todas las combinaciones posibles de características, estructura de red neuronal, segmentación de ventana y tipo de formación de imágenes. Nuestros hallazgos generales fueron los siguientes: 1) La CNN demostró el mejor rendimiento tanto para personas sanas como amputadas, 2) El grupo de características en el dominio del tiempo que utiliza información del espectro de potencia de una señal (TD-PSD), propuesto por primera vez en este trabajo, arrojó los mejores resultados, 3) La segmentación de ventana de 150 ms fue la más efectiva en todos los casos, 4) El tipo de imagen más eficaz fue una variante propuesta que reorganiza los canales de adquisición y las características extraídas mediante un algoritmo de adyacencia.

Además, como parte de nuestra metodología, evaluamos el rendimiento del modelo de clasificación eliminando iterativamente los datos de los movimientos con menor rendimiento. Esto nos permitió concluir que el rendimiento general del modelo mejora a medida que se excluyen los datos de los movimientos menos efectivos, y que los movimientos de mejor rendimiento varían de persona a persona.

En resumen, proponemos una metodología de clasificación de señales electromiográficas basada en los hallazgos mencionados en este estudio.

Abstract

The purpose of this work is to establish a methodology for acquiring, classifying, and interpreting electromyographic signals in individuals with hand disabilities or amputations, with the aim of developing an optimal classification model for electromechanical hand prosthetic applications or amputee rehabilitation. Our approach was based on a publicly available database containing myoelectric signals from 50 different movements of 40 healthy individuals and 11 amputees.

To achieve this, we employed four sets of features in the time domain (TD) and two deep neural network structures (Deep Learning): an Artificial Neural Network (ANN) and a Convolutional Neural Network (CNN). These networks were chosen due to their proven performance in the literature. Since our application involves decision-making in short time intervals, we worked with two different window segmentations, 200 ms and 150 ms, respectively. Furthermore, in the case of CNNs, we introduced an additional variable: the way to structure images to create the training and validation database. We explored four types of images, one of which was proposed by us for the first time in the literature.

To evaluate the results, we considered all possible combinations of features, neural network structure, window segmentation, and image formation type. Our overall findings were as follows: 1) CNN demonstrated the best performance for both healthy and amputated individuals, 2) The set of features in the time domain that uses information from the power spectrum of a signal (TD-PSD), proposed for the first time in this work, yielded the best results, 3) The 150 ms window segmentation was the most effective in all cases. 4) The most effective image type was a proposed variant that rearranges acquisition channels and extracted features using an adjacency algorithm.

Additionally, as part of our methodology, we iteratively evaluated the classification model's performance by removing data from movements with lower effectiveness. This allowed us to conclude that the overall model performance improves as less effective movement data is excluded, and that the movements with the best performance vary from person to person.

In summary, we propose a methodology for the classification of electromyographic signals based on the findings mentioned in this study.

Agradecimientos

En el proceso de culminar esta tesis, me gustaría expresar mi más sincero agradecimiento a todas las personas que contribuyeron de manera significativa a este logro.

En primer lugar, deseo extender mi gratitud al cuerpo docente del CIICAp (Centro de Investigación en Ingeniería y Ciencias Aplicadas) por su dedicación incansable a la enseñanza y su invaluable orientación a lo largo de mi educación. Cada uno de ustedes ha dejado una huella indeleble en mi desarrollo académico, y estoy profundamente agradecido por su conocimiento compartido y su inspiración.

En particular, quiero destacar al Dr. Álvaro Zamudio Lara y al Dr. José A. Marbán Salgado, quienes asumieron los roles de asesores de mi tesis. Su experiencia, paciencia y orientación experta fueron fundamentales en la realización de este proyecto. Sus consejos y perspicacia guiaron cada paso del camino, y estoy agradecido por la oportunidad de aprender de ustedes.

A mis padres, Luz María Espino Escobar y Jorge Sandoval Vera, les debo un agradecimiento especial. Su apoyo inquebrantable a lo largo de mi vida y especialmente durante este desafiante período académico ha sido mi fuente de fortaleza. Sus sacrificios y amor han sido mi mayor motivación.

A mi pareja, Lidia Gamboa Villa, le agradezco de corazón por su amor, comprensión y apoyo constante. Tu presencia en mi vida ha sido un faro de luz en los momentos más desafiantes.

A todos los amigos y seres queridos que me han alentado y brindado su apoyo moral, les estoy agradecido por estar siempre ahí.

Este logro no habría sido posible sin la contribución de cada uno de ustedes y su confianza en mi capacidad. A todos, mi más profundo agradecimiento.

ÍNDICE

CAPITULO 1. ANTECEDENTES	14
1.1 Introducción.....	15
1.2 Antecedentes	19
1.3 Pregunta de investigación	25
1.4 Hipótesis.....	25
1.5 Objetivo general	25
1.5.1 Objetivos específicos	25
CAPÍTULO 2. MARCO TEÓRICO	27
2.1 Señal mioeléctrica	28
2.1.1 Unidad motora (MU).....	29
2.1.2 Potencial de acción de la unidad motora (MUAP)	31
2.2 Adquisición de señales mioeléctricas	32
2.2.1 Señales mioeléctricas superficiales.....	34
2.2.1.1 Electrodo s superficiales.....	34
2.2.1.2 Configuración de canales de adquisición.....	35
2.3 Reconocimiento de patrones basado en control mioeléctrico	36
2.3.1 Segmentación de los datos	37
2.3.2 Extracción de características.....	38
2.3.2.1 Características en el dominio del tiempo.....	39
2.3.2.2 Características en el dominio de la frecuencia.....	39
2.3.2.3 Características en el dominio del tiempo-frecuencia	40
2.3.2.4 Características del espectro de potencia extraídas en el tiempo.....	40

2.3.3	Clasificación	43
2.3.3.1	Redes neuronales Artificiales (ANN)	43
2.3.3.1.1	Neurona biológica.....	44
2.3.3.1.2	Neurona artificial.....	44
2.3.3.1.3	Arquitectura neuronal artificial	46
2.3.3.1.4	Proceso de entrenamiento de una red neuronal artificial multicapa	47
2.3.3.1.5	Entrenamiento de la red neuronal.....	49
2.3.3.2	Redes neuronales convolucionales (CNN).....	50
2.3.3.2.1	Convolución.....	51
2.3.3.2.2	Capa convolucional	52
2.3.3.2.3	Pooling	53
CAPITULO 3.	METODOLOGÍA.....	54
3.1	Metodología para la adquisición de señales sEMG propias	55
3.1.1	Número y colocación de electrodos.....	55
3.1.2	Acondicionamiento de la señal	57
3.1.3	Adquisición de la señal.....	58
3.2	Metodología para clasificación de señales sEMG desde una base de datos existente	59
3.2.1	Descripción de Base de datos NINA PRO	59
3.2.1.1	Participantes.....	60
3.2.1.2	Colocación y número de electrodos	60
3.2.1.3	Descripción de los movimientos.....	61
3.2.1.4	Acondicionamiento y adquisición de las señales.....	63
3.2.1.5	Reetiquetado de la señal	64

3.2.1.6	Protocolo experimental	64
3.2.2	Clasificación de las señales sEMG.....	65
3.2.2.1	Procesamiento de la señal.....	66
3.2.2.2	Segmentación de ventanas seleccionada.....	67
3.2.2.3	Selección de grupos de características.....	68
3.2.2.4	Formación de imágenes	69
3.2.2.5	Clasificación	72
3.2.2.5.1	Clasificador ANN	73
3.2.2.5.2	Clasificador CNN	76
CAPÍTULO 4. RESULTADOS		79
4.1	Resultados implementando la estructura ANN	80
4.1.1	Base de datos DB2 implementando ANN.....	80
4.1.2	Base de datos DB3 implementando ANN.....	88
4.2	Resultados implementando la estructura CNN	95
4.2.1	Base de datos DB2 implementando CNN.....	95
4.2.2	Base de datos DB3	97
4.2.3	Comparación de tiempos de procesamiento	100
CAPITULO 5. DISCUSIÓN Y CONCLUSIONES		103
5.1	Discusión.....	104
5.2	Conclusiones.....	106
5.3	Metodología propuesta.....	107
CAPITULO 6. APENDICES		111
Apéndice A.	Información general de los sujetos de prueba de la base de datos NINA PRO DB2 y DB3.....	111

6.1 Apéndice B. Fórmulas de las características extraídas a las señales a las señales EMG	114
BIBLIOGRAFÍA.....	116

ÍNDICE DE FIGURAS

<i>Figura 2.1 Representación esquemática del mecanismo básico de control motor y de la unidad motora y sus componentes (Merletti & Parker, 2004).....</i>	<i>31</i>
<i>Figura 2.2 Generación del potencial de acción en una neurona excitada por el sistema nervioso central</i>	<i>32</i>
<i>Figura 2.3 Representación de la inserción de un electrodo de aguja en fibras musculares para la captación de los potenciales de acción.....</i>	<i>33</i>
<i>Figura 2.4 Electrodo de superficie Ag/ClAg para la adquisición de sEMG.....</i>	<i>35</i>
<i>Figura 2.5 Configuración monopolar para adquisición de señal sEMG.....</i>	<i>35</i>
<i>Figura 2.6 Configuración bipolar para adquisición de señal sEMG.....</i>	<i>36</i>
<i>Figura 2.7 Diagrama de bloques para el reconocimiento de patrones basado en control mioeléctrico.</i>	<i>37</i>
<i>Figura 2.8 Técnica de segmentación de ventanas: a) adyacentes, y b) traslapadas.</i>	<i>38</i>
<i>Figura 2.9 Transmisión de señal de una neurona biológica.</i>	<i>44</i>
<i>Figura 2.10 Neurona artificial</i>	<i>45</i>
<i>Figura 2.11 Función de activación Sigmoidea logarítmica (da Silva et al., 2017).....</i>	<i>46</i>
<i>Figura 2.12 Ejemplo de red neuronal de múltiples capas (da Silva et al., 2017).</i>	<i>47</i>
<i>Figura 2.13 Modelo de neurona j en una capa L.....</i>	<i>48</i>
<i>Figura 2.14. Estructura general de una red neuronal convolucional</i>	<i>51</i>
<i>Figura 3.1 Diagrama para el grabado de señales mioeléctricas.....</i>	<i>55</i>
<i>Figura 3.2 a) Colocación de los 6 canales sEMG, b) Distancia para la colocación del primer electrodo.</i>	<i>56</i>
<i>Figura 3.3 Posición del cuerpo para la adquisición de una señal sEMG del antebrazo.</i>	<i>57</i>
<i>Figura 3.4 Circuito amplificador a mil veces y filtro pasa banda de 4to orden de 20 a 500 Hz, para un canal de adquisición de señal sEMG.....</i>	<i>58</i>
<i>Figura 3.5 Tarjeta de adquisición de la marca ADVANTECH modelo USB 4716.</i>	<i>58</i>
<i>Figura 3.6 Colocación de electrodos, A.1 y B.1 Electrodo igualmente espaciados, A.2 electrodo en músculos flexores de los dedos, A.3 electrodo en el bíceps, B.2 electrodo en músculos extensores de los dedos, B.3 electrodo en el tríceps.....</i>	<i>61</i>
<i>Figura 3.7 A. Reposo, B. Movimientos básicos de dedos y de la muñeca, C. Movimientos funcionales y de agarre, D. Patrones de fuerza (Atzori, Gijssberts, Castellini, et al., 2014).....</i>	<i>63</i>
<i>Figura 3.8 Esquema del protocolo experimental. Los sujetos sentados frente a la pantalla de una computadora, donde pueden observar los movimientos y repetirlos.</i>	<i>65</i>
<i>Figura 3.9 Diagrama de bloques para la clasificación de señales mioeléctricas.</i>	<i>66</i>

<i>Figura 3.10 a) Señal EMG de 10 movimientos del canal 1 del sujeto 1, b) Reetiquetado de la señal utilizando el algoritmo de (Kuzborskij et al., 2012), c) Señal EMG ya concatenada.</i>	<i>67</i>
<i>Figura 3.11 Formación de imagen derivado de la extracción de características TD1.</i>	<i>70</i>
<i>Figura 3.12 Formación de imágenes para el entrenamiento de una CNN donde: a) Son las características por los canales (FeatureImage), b) son las características por los canales reorganizados (MixChannellImage), c) son las características reorganizadas por el número de canales (MixFeatureImage), y d) son las características reorganizadas por los canales reorganizados (MixImage).</i>	<i>72</i>
<i>Figura 3.13 Combinaciones de todos los esquemas probados en este estudio.</i>	<i>73</i>
<i>Figura 3.14 Estructura ANN empleada para la clasificación de 50 movimientos de la base de datos DB2 y DB3 para 12 canales de adquisición.</i>	<i>74</i>
<i>Figura 3.15 Algoritmo para calcular el rendimiento de clasificación al ir quitando los movimientos de menor rendimiento uno a uno.</i>	<i>75</i>
<i>Figura 3.16 Arquitectura GengNet para la clasificación de 50 movimientos de las bases de datos DB2 y DB3.</i>	<i>78</i>
<i>Figura 4.1 Promedio de rendimiento general para los 40 sujetos de la base de datos DB2 contra el número de movimientos clasificados para los 4 grupos de características propuestos.</i>	<i>80</i>
<i>Figura 4.2 Promedio del rendimiento general con variación para los 40 sujetos de la base de datos DB2 contra el número de movimientos clasificados, para características a)TD1, b)TD2, c)TD-PSD1 y D)TD-PSD2.</i>	<i>83</i>
<i>Figura 4.3 Codificación binaria en blanco y negro para los movimientos que permanecen (color negro) y los extraídos (color blanco) de 5 sujetos de la base de datos DB2, en la iteración a) 10, b) 20, c) 30 y d) 40 del algoritmo de la Figura 3.15, utilizando las características TD-PSD2.</i>	<i>84</i>
<i>Figura 4.4 Codificación binaria por colores para los movimientos que permanecen (color blanco) y los extraídos (color negro) de 2 sujetos de la base de datos DB2, en las 50 iteraciones del algoritmo de la Figura 3.15, utilizando características TD-PSD2.</i>	<i>86</i>
<i>Figura 4.5 Promedio de rendimiento general para los 11 sujetos de la base de datos DB3 contra el número de movimientos clasificados para los 4 grupos de características propuestos.</i>	<i>89</i>
<i>Figura 4.6 Promedio del rendimiento general con variación para los 40 sujetos de la base de datos DB3 contra el número de movimientos clasificados, para características a)TD1, b)TD2, c)TD-PSD1 y D)TD-PSD2.</i>	<i>91</i>
<i>Figura 4.7 Codificación binaria en blanco y negro para los movimientos que permanecen (color negro) y los extraídos (color blanco) de 5 sujetos de la base de datos DB, en la iteración a) 10, b) 20, c) 30 y d) 40 del algoritmo de la Figura 3.15, utilizando las características TD-PSD2.</i>	<i>92</i>

<i>Figura 4.8 Codificación binaria por colores para los movimientos que permanecen (color blanco) y los extraídos (color negro) de 2 sujetos de la base de datos DB3, en las 50 iteraciones del algoritmo de la Figura 3.15, utilizando características TD-PSD2.</i>	<i>93</i>
<i>Figura 4.9 Precisión en la clasificación utilizando los cuatro tipos de imágenes propuestas para entrenar una red CNN para la base de datos DB2 con un tamaño de ventana de: a)200 ms y traslape de 100 ms; b)150 ms y traslape de 25 ms.....</i>	<i>96</i>
<i>Figura 4.10 Precisión de la clasificación de los 40 sujetos de la base de datos DB2 utilizando las características TD-PSD2, los tipos de imagen MixChannel Image y Mix Image, con un tamaño de ventana de: a)200 ms y un traslape de 100 ms; b) 150 ms y un traslape de 25 ms.</i>	<i>97</i>
<i>Figura 4.11 Precisión en la clasificación utilizando los cuatro tipos de imágenes propuestas para entrenar una red CNN para la base de datos DB3 con un tamaño de ventana de: a)200 ms y traslape de 100 ms; b)150 ms y traslape de 25 ms.....</i>	<i>98</i>
<i>Figura 4.12 Precisión de la clasificación de los 40 sujetos de la base de datos DB2 utilizando las características TD-PSD2, los tipos de imagen MixChannel Image y Mix Image, con un tamaño de ventana de: a)200 ms y un traslape de 100 ms; b) 150 ms y un traslape de 25 ms.</i>	<i>99</i>
<i>Figura 4.13 Tiempo de procesamiento para la clasificación de una muestra relativo al tiempo de procesamiento utilizando las características TD-PSD2 con el tipo de imagen "Mix Image".....</i>	<i>101</i>
<i>Figura 5.1 Metodología para la adquisición de señales sEMG para la clasificación de patrones de mano.</i>	<i>108</i>
<i>Figura 5.2 Metodología para la clasificación de patrones de mano utilizando redes neuronales convolucionales.</i>	<i>109</i>

ÍNDICE DE TABLAS

<i>Tabla 1.1 Trabajos previos de clasificación de movimientos de mano utilizando señales mioeléctricas. ANN (artificial neural network), MLFFANN (Multilayer Feed Forward Artificial Neural Network), FFMLP (Feed Forward Multilayer Perceptron), SVM (Support Vector machine), LDA (Linear Discriminant Analysis), CNN (Convolutional Neural Network).....</i>	<i>21</i>
<i>Tabla 2.1 Rangos de algunas de las bioseñales más usuales (Guerrero Martínez, 2010).....</i>	<i>28</i>
<i>Tabla 2.2 Descripción de las 5 características TD-PSD2.</i>	<i>42</i>
<i>Tabla 3.1 Grupos de características TD utilizados en este proceso experimental.</i>	<i>69</i>
<i>Tabla 4.1 R, R2, RMSE y MAPE para los 20 mejores movimientos del sujeto 1 de la base de datos DB2, calculados en la iteración 1 y en la iteración 30 del algoritmo general de procesamiento</i>	<i>87</i>
<i>Tabla 4.2 R, R2, RMSE y MAPE para los 20 mejores movimientos del sujeto 2 de la base de datos DB3, calculados en la iteración 1 y en la iteración 30 del algoritmo general de procesamiento.</i>	<i>94</i>
<i>Tabla 4.3 Precisión de clasificación más alta lograda para las bases de datos DB2 y DB3.....</i>	<i>100</i>
<i>Tabla 4.4 Tamaño de cada imagen relativo al tamaño de la imagen con el mejor rendimiento mostrado (dado en porcentaje).....</i>	<i>102</i>
<i>Tabla 5.1 Precisión de clasificación del esquema propuesto y de trabajos previos utilizando las bases de datos DB2 y DB3.</i>	<i>105</i>

CAPITULO 1. ANTECEDENTES

En este capítulo se da una breve introducción al tema de las señales mioeléctricas y sus aplicaciones, resaltando la importancia de desarrollar investigación en México orientada a esta área. Además, se presentan los antecedentes del trabajo, así como los objetivos, la hipótesis y la justificación del proyecto.

1.1 Introducción

En México existían hasta el 2014 alrededor de 7.1 millones de habitantes con alguna discapacidad, de los cuales el 33% presentaban discapacidad para mover o usar sus brazos o manos (INEGI, 2016), que sumados a las más de 25 mil personas que sufren de la amputación de alguna de sus extremidades en forma anual (Academia Nacional de Medicina, 2016), resultan en un amplio grupo de personas quienes enfrentan múltiples obstáculos para hacer ejercer todos los derechos que establece el orden jurídico mexicano, sin distinción de origen étnico, nacional, género, edad, condición social, económica o de salud, religión, opiniones, estado civil, preferencias sexuales, embarazo, identidad política, lengua, situación migratoria o cualquier otra característica propia de la condición humana o que atente contra su dignidad (DOF, 2011).

Una gran parte de estas personas cuentan con una prótesis que les permite afrontar de mejor manera los retos de la vida diaria, las prótesis pueden ser cosméticas, cinemáticas o electromecánicas, estas últimas, suelen ser más funcionales pero también más costosas en su implementación. En este sentido, los avances tecnológicos con la creación de materiales cada vez más ligeros y resistentes, los engranajes articulares y el aspecto estético de las prótesis, ha mejorado sustancialmente permitiendo que las prótesis que se fabrican, implantan y adaptan, sean cada vez más eficientes permitiendo una mejor y más rápida rehabilitación. Sin embargo, la mayoría de las prótesis electromecánicas disponibles hoy en día, están lejos de satisfacer las necesidades de la vida real, debido a que capacidades limitadas de control, el control es con frecuencia no natural y los tiempos de entrenamiento suelen ser muy largos (Atzori, Gijsberts, Castellini, et al., 2014). Además, este tipo de prótesis, están limitadas a unos cuantos gestos, debido a que los métodos para adquirir, clasificar e interpretar las señales musculares han demostrado bajo nivel de rendimiento en ambientes no controlados.

La adquisición de señales electromiografías superficiales (sEMG), las cuales son señales eléctricas producidas por el musculo en el proceso de contracción y relajación, están experimentando un creciente interés en las áreas de diagnósticos médicos, interacción con aplicaciones, interfaces máquina-humano (HMIs), y por supuesto, en el control de prótesis electromecánicas (*Milosevic et al., 2017*), siendo también consideradas de mucha utilidad como señales electrofisiológicas en otros campos de la ingeniería y de la medicina (*Chowdhury et al., 2013*). Esto, debido a que su adquisición es posible mediante electrodos colocados en la superficie de la piel de forma no invasiva. No obstante, los problemas asociados con la adquisición de señales sEMG son varios, y en lo general se pueden clasificar en dos grupos, por un lado están los problemas extrínsecos, los cuales están asociados a la estructura del electrodo y su colocación en el área de interes, y por otro lado, están los problemas intrínsecos, que están asociados a las características fisiológicas, anatómicas y bioquímicas de los músculos (C. J. De Luca, 1997). Todo ello, dificulta la estimación de la amplitud de una señal sEMG para obtener una buena precisión y representatividad. En un impulso neuronal constante a un musculo, la amplitud de sEMG puede ser variable y por lo tanto carecer de precisión. Representatividad, se refiere a la señal que representa a todo el musculo bajo estudio y nada más que el musculo bajo estudio (*Staudenmann et al., 2010*).

Se han realizado grandes esfuerzos con la intención de reducir todos los problemas asociados a la adquisición de este tipo de señales, derivado de eso, la mayoría de los estudios reportan la utilización de múltiples canales electromiográficos (2 electrodos por canal en configuración bipolar, más un electrodo de referencia común para todos los canales) para recabar la mayor cantidad de información posible, y así lograr mejores niveles de precisión al momento de clasificar dichas señales como un conjunto, buscando patrones

asociadas a la contracción de un musculo o conjunto de músculos que generan un movimiento o gesto de una extremidad.

Sin embargo, debido a que las señales mioeléctricas, por naturaleza, son señales estocásticas, no lineales y no estacionarias (*Farina et al., 2002*), su clasificación se ha convertido en un gran reto cuando se pretende clasificar un gran número de gestos para su implementación en el control de una prótesis de mano, más aún, si se trata de personas que tengan algún tipo de amputación de sus extremidades. Estudios anteriores demuestran que las precisiones logradas para clasificación de gestos utilizando señales adquiridas de personas con algún tipo de discapacidad o amputación de mano, han tenido rendimientos más bajos que en personas sin ningún tipo de amputación, y esto se debe, entre otras cosas, a las características únicas de una amputación o falta de una extremidad, por ejemplo, tiempo desde la amputación, nivel de amputación, estructura muscular distinta después de la amputación, la presencia de lesiones nerviosas, etc. (A. H. Al-Timemy et al., 2016).

Debido a la complejidad de las señales sEMG, resulta impráctico el análisis de la señal sin ningún tipo de procesamiento, debido a ello, el procedimiento típico a seguir para el control de una prótesis usando este tipo de señales es: la adquisición de la señal sEMG, el procesamiento digital de la señal, la segmentación de los datos, la extracción de características, y finalmente su clasificación (*Gao et al., 2021*)

La mayoría de los trabajos en este campo de aplicación, se han enfocado en definir el número de electrodos ideal para adquirir las señales sEMG, las características ideales a extraer de la señal, los movimientos más óptimos y la cantidad de movimientos a clasificar, y el mejor y más robusto método de clasificación de señales EMG, sin embargo, las variables son muchas, y discutir resultados obtenidos bajo ciertas condiciones con otros trabajos que lo han hecho con condiciones parecidas podría llegar a ser engañoso, puesto que, como se mencionó antes, incluso las capacidades fisiológicas de una

persona afectan la adquisición de una señal. Debido a esto, varios equipos de trabajo a lo largo del mundo han hecho el esfuerzo por publicar bases de datos de señales mioeléctricas obtenidas bajo ciertas condiciones, con la finalidad de poder discutir resultados de nuevos métodos propuestos sobre los mismos datos adquiridos, las bases de datos publicas más utilizadas son MIT-BIH, PhysioNet, BCI competition II, CHB-MIT, DEAP, Bonn University, y NinaPro. Según el estudio realizado por (*Rim et al., 2020*) la base de datos más utilizada para el análisis de señales sEMG es NinaPro, ya que cuenta con señales obtenidas de varias personas, tanto amputadas como no amputadas, con hasta 12 canales de adquisición, y para hasta 50 movimientos diferentes, siendo la más completa al momento.

Actualmente existen varios métodos para clasificar señales EMG enfocadas al control de una prótesis, dentro de los cuales, los más utilizados por sus buenos rendimientos se encuentra el método de análisis discriminante lineal (LDA), introducido por primera vez hace más de 80 años para la solución de problemas de clasificación (*Fisher, 1936*), el método de soporte de máquinas de vectores (SVM), explicado a profundidad por (*Cortes & Vapnik, 1995*), y más recientemente la utilización de estructuras de redes neuronales artificiales (ANN), cuyos principios básicos surgieron gracias a (*Rosenblatt, 1958*) y su explicación del perceptron, y por último, las redes neuronales convolucionales (CNN), aplicadas por primera vez por (*LeCun et al., 1989*), siendo un parteaguas en muchos campos de aplicación para la clasificación de imágenes.

Debido a las discrepancias en rendimientos entre trabajos muy similares, y a la cantidad de factores tanto fisiológicos como de adquisición de señales, que pueden afectar el rendimiento de clasificación de movimientos de una persona a otra, este trabajo propone el diseño y la implementación de una metodología para adquirir, clasificar e interpretar señales sEMG, con la intención de definir el número de movimientos, el tipo de características a extraer de la señal y el

método de clasificación que den el mejor rendimiento para un grupo de personas sin ningún tipo de amputación, y para un grupo de personas con algún tipo de amputación o discapacidad, haciendo uso de una base de datos publica para poder discutir los resultados con trabajos similares.

1.2 Antecedentes

En trabajos relacionados a la clasificación de gestos utilizando señales sEMG, se ha demostrado que, la clasificación del movimiento de los dedos es más compleja que la clasificación de los movimientos generales de la mano debido a varios factores, entre los que se encuentran: el tamaño de los músculos involucrados, la amplitud de las señales EMG y la cantidad de grados de libertad que se encuentran en los dedos de manera combinada. Es por esa razón que se han logrado mejores precisiones al clasificar únicamente movimientos generales de la mano que cuando se intentan clasificar los movimientos de los dedos. (*Arica et al., 2017*) Lograron precisiones de hasta el 83.5% al clasificar 5 movimientos de mano utilizando 4 canales EMG ubicados en posiciones estratégicas del antebrazo, las pruebas fueron realizadas en 2 hombres y 2 mujeres completamente sanos y utilizaron el método de clasificación llamado SVM. Por otro lado, (*Patel et al., 2018*) propusieron un nuevo método de clasificación inspirado en la coordinación muscular, el estudio fue realizado sobre 10 personas completamente sanas y una persona amputada y la adquisición fue hecha mediante 8 canales EMG en configuración bipolar, al comparar su método con el método LDA, reportaron una mejora de rendimiento de hasta un 22% en la persona amputada. También se han realizado múltiples trabajos enfocados en la clasificación de movimientos únicamente de dedos, donde la optimización del número de canales sEMG a utilizar manteniendo niveles de precisión alta ha sido una de las problemáticas a resolver. Por ejemplo, de los 32 canales que utilizaron (*F. V. G. Tenore et al., 2009*) para clasificar 12 movimientos de dedos

en personas saludables, a los 6 canales que utilizaron (*A. H. Al-Timemy et al., 2013*) para clasificar 15 movimientos de dedos en personas saludables con una precisión de hasta el 98% para algunos movimientos, ha habido una mejoría sustancial. Sin embargo, este último también realizó el estudio sobre un grupo de 6 personas amputadas teniendo errores hasta del 18 % para algún tipo de movimientos, concluyendo que los movimientos en personas amputadas son más difíciles de clasificar.

Han sido pocos los trabajos dedicados a la validación de los métodos en personas con alguna discapacidad o tipo de amputación, y los pocos que lo han considerado han concluido una baja en el rendimiento con respecto a las personas sanas. Los mismos (*A. H. Al-Timemy et al., 2016*) realizaron otro estudio donde demostraron que entre más movimientos se pretenden clasificar con personas amputadas más grande es el error, independientemente del método a utilizar, para lo cual, estudiaron 4 combinaciones de métodos de reducción de características y clasificadores de movimientos, aplicados a 4 personas con distintos niveles de amputación. Es claro que, a pesar de los varios trabajos realizados en el tema, aun no parece haber una conclusión clara de los parámetros idóneos bajo los cuales se debe hacer la adquisición de las señales mioeléctricas, ni del método de clasificación que de los mejores rendimientos, ni de las características idóneas para obtener la mejor clasificación, ni cuáles son los mejores movimientos para obtener un buen resultado al momento de aplicar cualquiera de los métodos de clasificación.

La Tabla 1.1 muestra algunos de los trabajos más citados al respecto, donde por un lado podemos ver que el número de canales utilizados en la adquisición es distinto en la mayoría, algunos realizan el estudio para movimientos generales de mano (combinados) , otros para movimientos de dedos, y algunos intentan clasificar ambos, la tabla también muestra el número de sujetos con el que fue hecho el estudio, y si son personas sin ninguna amputación (sanas) o personas con algún tipo de amputación de mano, los

métodos de clasificación utilizados son variados, aunque predomina el uso de algoritmos de machine learning y Deep learning, principalmente Redes Neuronales Artificiales (ANN).

Tabla 1.1 Trabajos previos de clasificación de movimientos de mano utilizando señales mioeléctricas. ANN (artificial neural network), MLFFANN (Multilayer Feed Forward Artificial Neural Network), FFMLP (Feed Forward Multilayer Perceptron), SVM (Support Vector machine), LDA (Linear Discriminant Analysis), CNN (Convolutional Neural Network)

Referencia	Numero canales	Numero de movimientos	Precisión de clasificación	Número de personas	Método de clasificación
(Hudgins et al., 1993)	1	4 (combinados)	91% 85%	4(sanas) 1(amputadas)	ANN
(M. W. Jiang et al., 2005)	4	6 (dedos)	87 %	10 (sanas)	ANN
(Sebelius et al., 2005)	8	4 (dedos) 6 (combinados)	90 %	11 (sanas) 6 (amputadas)	ANN
(F. Tenore et al., 2007)	32	12 (dedos)	98%	1(sana)	MLFFANN
(F. V. G. Tenore et al., 2009)	32 (no amputados) 19(amputados)	12 (dedos) 12 (combinaciones)	94.1% 87.8	5(sanas) 1(amputadas)	FFMLP
(Naik et al., 2009)	4	4 (combinaciones)	96%	7(sanas)	ANN
(Kanitz et al., 2011)	16	13 (dedos)	80%	5(sanas) 1(amputadas)	SVM
(Cipriani et al., 2011)	8	7 (dedos) 7 (combinaciones)	89% 79%	5(sanas) 5(amputadas)	Lazy learning
(Ibn Ibrahimy et al., 2013)	1	4 (combinados)	85%	3(sanas)	ANN(Optimización)
(A. H. Al-Timemy et al., 2013)	6	15 (dedos) 12 (combinaciones)	98.25% 90.57%	10(sanas) 6(amputadas)	SVM LDA

(Adewuyi et al., 2016)	9	4 (combinaciones)	98%	16(sanas) 4(amputadas)	MLPANN
(A. H. Al-Timemy et al., 2016)	6	8(combinaciones)	97%	4(amputadas)	LDA
(Abbaspour et al., 2020)	4	11(combinaciones)	97%	20(sanas)	Varios
(Yamanoi et al., 2020)	5	9 (combinaciones)	88% 37%	3 (sanas) 1 (amputada)	CNN

Recientemente, el uso de CNN para clasificar este tipo de señales ha cobrado mayor relevancia debido a los buenos resultados mostrados (Atzori et al., 2016a; Y. Du et al., 2017; Geng et al., 2016; Hu et al., 2018a). Para la implementación de una CNN la señal sEMG tiene que ser considerada como una imagen, en ese sentido, la interpretación de la señal para entrenar la red, según la literatura, puede ser dividida en dos, la primera es obtener una ventana en el tiempo, esta imagen estará compuesta por el número de canales (alto) por el número de datos en el tiempo (ancho), (Park & Lee, 2016) utilizaron este tipo de imágenes para generar un modelo entrenado por datos de varios sujetos, y obtuvieron mejor rendimiento que al implementar SVM. Por otro lado, como se mencionó en el capítulo anterior, actualmente es muy común la validación de nuevos modelos en bases de datos públicas, lo cual permite discutir resultados con trabajos similares, por ejemplo, (Atzori et al., 2016a) utilizaron la misma representación de imagen para clasificar las bases de datos DB1, DB2 y DB3 del proyecto denominado NinaPro (Atzori et al., 2015), y utilizando una CNN compararon los rendimientos con métodos de clasificación tradicionales, tales como k-NN, SVM, Random Forest, y LDA, demostrando que los rendimientos fueron comparables incluso utilizando una estructura de red CNN muy sencilla, revelando así una nueva área para explorar. La segunda forma de representar una imagen es la propuesta por (Geng et al., 2016), quienes introdujeron el concepto de “imagen sEMG

instantánea”, la cual consiste en obtener las señales sEMG a través de un arreglo de alta densidad de canales de adquisición espaciados muy cerca uno de otro, y así grabar la actividad eléctrica de los músculos en un área específica, cada valor de cada canal representa el valor de cada pixel de la imagen formada, lo cual permite el análisis de las señales sEMG en tiempo y el espacio, para su trabajo ellos evaluaron el rendimiento de la clasificación utilizando estas imágenes en un esquema CNN implementado sobre tres bases de datos públicas, NinaPro DB1, NinaPro DB2 y CSL-HDEMG (*Amma et al., 2015*), sus resultados mostraron que, de hecho, hay patrones dentro de una imagen instantánea con los que se pueden reconocer los gestos, abriendo un nuevo panorama para el análisis de señales sEMG. (Y. Du et al., 2017) también utilizaron este tipo de imagen para evaluar el rendimiento en la clasificación utilizando una estructura CNN en tres bases de datos, NinaPro DB1, CSL-HDEMG, y CapgMyo, esta última generada por ellos mismos, además, propusieron un esquema adaptativo en el dominio profundo para la clasificación de gestos, lo que incremento el rendimiento publicado en trabajos previos. Por otro lado, antes de iniciar con el uso de estructuras CNN para la clasificación de patrones, y como se mencionó en el capítulo anterior, el modo más común de clasificación está basado en la extracción de características y el entrenamiento de algoritmos de machine learning (*A. H. Al-Timemy et al., 2013, 2016; L. Hargrove et al., 2008; L. J. Hargrove et al., 2007; Phinyomark et al., 2009, 2012; Rechy-Ramirez & Hu, s. f.*) y de Deep learning, principalmente redes neuronales (*Adewuyi et al., 2016; A. Al-Timemy et al., 2018; Hudgins et al., 1993; Oweis et al., 2014; F. V. G. Tenore et al., 2009*). Las características más utilizadas son aquellas extraídas en el dominio del tiempo (TD), debido a su buen rendimiento y porque no requieren transformación alguna, y además no requieren mucho tiempo computacional (*Rechy-Ramirez & Hu, s. f.*). Regresando a esos inicios y al mismo tiempo considerando los buenos rendimientos mostrados por las estructuras CNN, algunos trabajos han optado por formar imágenes usando la extracción de

características de la señal para entrenar redes CNN, (Hu et al., 2018a) utilizaron el set de características TD tomadas de (*Phinyomark et al., 2012*) para proponer una nueva representación de imágenes sEMG, donde el ancho de la imagen es el número de características y el alto de la imagen es el número de los canales reorganizados como lo propone (*W. Jiang & Yin, 2015*), ellos evaluaron el rendimiento utilizando una CNN, un híbrido CNN-RNN y una CNN híbrida basada en la atención sobre cuatro bases de datos, NinaPro DB1, NinaPro DB2, BioPatRec, y CapgMyo, obteniendo el mejor rendimiento publicado hasta ese momento para todos los casos.

Más adelante, (Wei et al., 2019a) utilizaron la misma técnica para generar imágenes para evaluar el rendimiento de ocho sets de características TD, y tres más derivados de la transformada Wavelet, ellos utilizaron una nueva estructura CNN de múltiples vistas sobre varias bases de datos, entre las cuales están la NinaPro y la BioPatRec, obteniendo mejor rendimiento que sus predecesores. Por otro lado, basados en la idea de que este tipo de señales son por naturaleza no lineales y estocásticas, (*Pancholi et al., 2021*) propuso extraer dos características derivadas del espectro de potencia en el tiempo (TD-PSD) para estabilizar la señal y reducir el tamaño de entrenamiento de la base de datos, con esas características y utilizando una red CNN mejoraron el rendimiento sobre las bases de datos NinaPro DB1, DB2 y DB3.

Sin duda, muchos progresos se han hecho en los últimos años en la generación de modelos matemáticos para obtener el mejor rendimiento, lo cual permite su implementación en una prótesis real y que sus movimientos sean cada vez más naturales, sin embargo, aún existe la interrogante de cuál es el mejor método para clasificar señales desde la obtención de la señal misma hasta la obtención del modelo de clasificación, en este proyecto se pretende definir una metodología clara que permita facilitar, y estandarizar este proceso para personas amputadas y no amputadas, y así obtener el mejor modelo posible para persona en particular.

1.3 Pregunta de investigación

De acuerdo al tipo de amputación de una persona ¿Es posible adecuar una metodología para seleccionar el tipo de características a extraer de las señal SEMG, la cantidad y el tipo de movimientos a clasificar, y el método de clasificación, para obtener el mejor rendimiento posible de clasificación de movimientos de mano y dedos?

1.4 Hipótesis

Personalizar la adquisición de señales EMG y la clasificación de movimientos combinados para cada persona con grados de discapacidad o amputación distinta, mejorara la precisión lograda en la clasificación e interpretación de las mismas.

1.5 Objetivo general

Desarrollar e implementar una metodología para la extracción de características, clasificación e interpretación de señales electromiográficos obtenidas de personas con algún tipo de discapacidad o amputación de mano.

1.5.1 Objetivos específicos

1. Diseñar e implementar un sistema de adquisición y filtrado de señales EMG con al menos 6 canales en configuración bipolar.
2. Diseñar e implementar un software en la plataforma de LabVIEW para visualizar y manipular señales EMG.
3. Implementar al menos dos métodos de clasificación de señales EMG existentes en la literatura para clasificar movimientos combinados de dedos y movimientos generales de la mano, en personas sin ningún tipo de discapacidad.

4. Implementar los mismos métodos del objetivo anterior a personas con algún tipo de discapacidad o amputación de mano.
5. Proponer e implementar una metodología para la adquisición y clasificación de señales en personas con algún tipo de discapacidad o amputación de mano.

CAPÍTULO 2. MARCO TEÓRICO

En este capítulo se definen los conceptos, métodos y formulas necesarias para el desarrollo del procedimiento experimental, que incluye la adquisición de las señales mioeléctrica, el procesamiento digital y la clasificación de gestos.

2.1 Señal mioeléctrica

El registro de señales biológicas proporciona una puerta de entrada para comprender como se comporta el cuerpo humano en condiciones normales y en condiciones patológicas (*Cavalcanti Garcia & M. Vieira, 2010*), por ejemplo, se puede medir el ritmo cardiaco, la actividad cerebral, la presión sanguínea, etc. cada una de estas bioseñales tiene un rango de amplitud definido y un rango de frecuencias que es importante considerar al momento de instrumentar los sistemas de adquisición para estas señales. La Tabla 2.1 muestra las bioseñales más típicas así como sus rangos de amplitud y de frecuencias típicas.

Tabla 2.1 Rangos de algunas de las bioseñales más usuales (*Guerrero Martínez, 2010*)

Bioseñal	Definición	Rango de Amplitud	Rango de frecuencias
Electrocardiograma (ECG)	Actividad eléctrica cardiaca	0.5 – 4 mV	0.01 – 250 Hz
Electroencefalograma (EEG)	Actividad eléctrica cerebral	5 – 300 μ V	DC – 150 Hz
Electrogastrograma (EGG)	Actividad eléctrica gástrica	10 μ V – 1 mV	DC – 1 Hz
Electromiograma (EMG)	Actividad eléctrica muscular	0.1 – 5 mV	DC – 10 kHz
Electroneurograma (ENG)	Actividad eléctrica nerviosa	0.01 – 3 mV	DC – 1 kHz
Electrooculograma (EOG)	Potencial retina-córnea	50 – 3500 μ V	DC – 50 Hz
Electrorretinograma (ERG)	Actividad eléctrica de la retina	0 – 900 μ V	DC – 50 Hz
Fonocardiograma (PCG)	Sonidos cardíacos	80 dB (rango dinámico) 100 μ Pa (umbral)	5 – 2000 Hz
Flujo sanguíneo	Flujo sanguíneo	1 – 300 ml/s	DC – 20 Hz
Gasto cardíaco	Sangre bombeada p/ unidad de tiempo	4 -25 litros/minuto	DC – 20 Hz
pH sanguíneo	Medida del pH en sangre	6.8 – 7.8 unid. pH	DC – 2 Hz

Plestitimografía	Medida de cambios de volumen	Depende del órgano medido	DC – 30 Hz
Pneumotacografía	Medida del flujo respiratorio	0 – 600 litros/minuto	DC – 40 Hz
Potencial acción	Potencial característico de diferentes células	100 mV	2 kHz
Potenciales evocados (EP)	Respuestas cerebrales evocadas por estímulos sensoriales	0.1 – 10 μ V	0.5 – 3 kHz
Presión arterial	Presión sanguínea arterial	10 – 400 mm Hg	DC – 50 Hz
Presión venosa	Presión sanguínea venosa	0 – 50 mm Hg	DC – 50 Hz
Respuesta galvánica de la piel (GSR)	Potencial generado por la actividad de las glándulas sudoríparas de la mano	1 – 500 k Ω	0.01 – 1Hz

Para el caso de este trabajo, se pretende la adquisición de señales mioeléctricas, las cuales son señales producidas por los músculos en su proceso de contracción y relajación. La electromiografía por lo tanto, es el estudio de la función muscular a través de la investigación de la señal eléctrica de ellos emana (*Basmajian, 1967*).

2.1.1 Unidad motora (MU)

La señal mioeléctrica nace desde el sistema nervioso central, el cual mediante neuronas llamadas “motoneuronas α ” controlan el sistema motor del ser humano. En la Figura 2.1 se presenta el esquema general del sistema motor central, que nace en la corteza del cerebro donde motoneuronas α tienen una comunicación directa con interneuronas y motoneuronas α localizadas en el

tronco encefálico y en la medula espinal respectivamente. La comunicación entre el tracto cortico espinal y las motoneuronas α proporciona un control cortical directo de la actividad muscular, la Figura 2.1 también muestra un esquema unitario de lo que se le conoce como unidad motora (MU por sus siglas en ingles), el cual consiste en una motoneurona α en la medula espinal conectada a las fibras musculares que inerva (*Merletti & Parker, 2004*), cuando el sistema nervioso pretende inervar un musculo recluta varias de estas MU dependiendo de la fuerza requerida y el musculo en cuestión, subsecuentemente ocurre una despolarización en la fibra muscular provocando su contracción, esta despolarización inicia en la mitad de la unión neuromuscular de la neurona y se propaga en direcciones opuestas a lo largo del musculo hasta alcanzar los extremos de la fibra muscular (*Staudenmann et al., 2010*). El número de MU en humanos puede variar desde 100 y hasta 1000 dependiendo de los factores antes mencionados (*Henneman & Mendell, 1981*). Además, las neuronas reclutadas no suelen ser las mismas ni la misma cantidad de ellas a pesar de inervar el mismo musculo en múltiples ocasiones, lo cual dificulta sobremanera el análisis de este tipo de señales por métodos simples, como por ejemplo encontrar una frecuencia asociada a un movimiento en particular.




Figura 2.1 Representación esquemática del mecanismo básico de control motor y de la unidad motora y sus componentes (Merletti & Parker, 2004).

2.1.2 Potencial de acción de la unidad motora (MUAP)

Las membranas celulares típicamente tienen una diferencia de potencial entre su parte interna y su parte externa aproximadamente de -80 mV a -90 mV , cuando el sistema nervioso central induce una activación sobre las motoneuronas provoca que iones de sodio (Na^+) fluyan dentro de la membrana y que iones de potasio (K^+) escapen de la membrana, esto provoca una despolarización en la membrana de la célula provocando un incremento en la diferencia de potencial, si esa diferencia de potencial rebasa potencial de umbral el cual se encuentra alrededor de los -55 mV , éste llegara rápidamente a un potencial de acción alrededor de los 30 mV que provocara una reacción en cadena a lo largo de membrana celular, a este fenómeno, que puede pensarse como un circuito de un solo disparo se le conoce como el potencial de acción de la unidad motora (MUAP), la forma de esta diferencia de potencial

cuando ocurre la activación motora puede observarse en la Figura 2.2, inmediatamente después el potencial es restaurado debido a una fase de repolarización. El MUAP que parte de las motoneuronas, y se propaga a lo largo de las membranas celulares, finalmente inerva los músculos produciendo un acortamiento de los elementos contráctiles de la célula muscular (Konrad, 2005).




Figura 2.2 Generación del potencial de acción en una neurona excitada por el sistema nervioso central

El MUAP resultante es la sumatoria de los MUAPs reclutados por el sistema nervioso para la inervación de cada músculo en particular.

2.2 Adquisición de señales mioeléctricas

Una señal mioeléctrica, la cual es generada sobre las fibras musculares, puede adquirirse de diferentes maneras, mediante electrodos de aguja, electrodos de superficie o electrodos de alambre (Hallett et al., 1994). Los electrodos de aguja son más selectivos (Ver Figura 2.3), y dependiendo del tipo de electrodo utilizado los MUAPs adquiridos pueden ser derivados del potencial de acción

de una o varias MU. Los electrodos de alambre son muy parecidos a los de aguja con la diferencia de que los de alambre se inserta sobre las fibras musculares por un largo periodo de tiempo, por lo que, tienen la selectividad de los electrodos de aguja y permiten mayor libertad de movimiento sin ingresar ruido a la señal.




Figura 2.3 Representación de la inserción de un electrodo de aguja en fibras musculares para la captación de los potenciales de acción.

El problema con los electrodos de aguja y de alambre es que son formas de medición invasiva, es decir, el electrodo o el alambre deben ir incrustados en las fibras musculares, los electrodos de superficie por otro lado, tienen la ventaja de no ser dolorosos, no ser invasivos, y de recabar información de un

gran volumen de músculos a la vez, por esta razón, este tipo de adquisición es el más utilizado para muchas aplicaciones, incluyendo la clasificación de gestos para el control de prótesis.

2.2.1 Señales mioeléctricas superficiales

Cuando se utilizan electrodos de superficie para la adquisición de señales mioeléctricas, la literatura típicamente lo define como electromiografía de superficie o señales mioeléctricas superficiales (sEMG), y al electrodo sEMG puede ser definido como un sensor de actividad eléctrica muscular o como un transductor de corriente iónica (*Merletti et al., 2009*).

2.2.1.1 Electrodoes superficiales

Los electrodos superficiales son colocados directamente sobre la piel del musculo o grupo de músculos del cual se quiere obtener la información, la superficie del electrodo actúa como transductor, dando un valor medio del campo de potencial alrededor de la superficie. Los electrodos más utilizados para estas aplicaciones están hechos de plata (Ag) con una ligera capa de cloruro de plata (ClAg) el cual se pone en contacto con la piel mediante una pasta electrolítica, estos sensores se utilizan en un 80% de las aplicaciones de señales sEMG debido a sus bajos valores de impedancia piel/electrodo (*Duchene & Goubel, 1993*). Para este proyecto se decidió utilizar electrodos superficiales de la marca COVIDEN de Ag/ClAg los cuales se muestran en la Figura 2.4.



Figura 2.4 Electrodo de superficie Ag/ClAg para la adquisición de sEMG.

2.2.1.2 Configuración de canales de adquisición

La colocación de los electrodos para la adquisición de señales sEMG puede hacerse principalmente a través de dos configuraciones: monopolar y bipolar (Zahak, 2012). En la configuración monopolar se coloca un electrodo sobre la piel de la zona donde se quiere adquirir la señal, y otro electrodo se utiliza como referencia (C. De Luca, 2006) y se coloca en una parte de piel que sea eléctricamente neutra como se muestra en la Figura 2.5.




Figura 2.5 Configuración monopolar para adquisición de señal sEMG.

En la configuración bipolar se utilizan dos electrodos para adquirir la señal sEMG sobre el musculo de interés, separados una distancia ideal de 10 mm y colocados a lo largo de la extensión del musculo en cuestión (Freriks &

Hermens, 1999), además, se utiliza un tercer electrodo como referencia al igual que en la configuración monopolar (Ver Figura 2.6). La adquisición de esta señal es amplificada con la ayuda de un amplificador diferencial de instrumentación el cual suprime el ruido común de ambas entradas y después amplifica la diferencia (*C. De Luca, 2006*), debido a esta gran ventaja esta configuración es la más utilizada para este tipo de aplicaciones.




Figura 2.6 Configuración bipolar para adquisición de señal sEMG.

Para la adquisición de las señales de este proyecto se decidió utilizar la configuración bipolar para múltiples canales, donde se considera una única referencia para todas las señales.

2.3 Reconocimiento de patrones basado en control mioeléctrico

Debido a la complejidad de las señales sEMG y a su baja repetitividad, la clasificación de las mismas se vuelve un tema difícil de resolver, la mejor forma de hacerlo es la identificación y clasificación de patrones teniendo múltiples canales de adquisición, estas señales son amplificadas, filtradas digitalizadas vía instrumentos EMG estándar y finalmente transferidas a un controlador

(Asghari Oskoei & Hu, 2007), el cual incluye principalmente los módulos señalados en la Figura 2.7.




Figura 2.7 Diagrama de bloques para el reconocimiento de patrones basado en control mioeléctrico.

2.3.1 Segmentación de los datos

Debido a que este proyecto está enfocado a generar un modelo para su posterior implementación en el control de una prótesis electromecánica de mano, los tiempos en los que se deben tomar decisiones son relativamente cortos, debido a ello se debe realizar una segmentación de los datos a analizar en ventanas de tiempo, y así analizar cada ventana, procesarla, y con ellas entrenar un modelo de clasificación. El tamaño de ventana debe seleccionarse con cuidado debido a que debe haber un equilibrio entre el tiempo de respuesta y la mejor precisión alcanzada, el tiempo de respuesta de un sistema de control de este tipo no debe tener un retardo perceptible para el usuario, en general, se considera que este tiempo debe estar por debajo de 300 ms, esto impone una restricción en tiempo real a las tareas del sistema de control de adquirir y procesar los datos mioeléctricos (Englehart & Hudgins, 2003). Existen dos técnicas para la segmentación de ventanas: la técnica de ventanas adyacentes y la técnica de ventanas traslapadas (Asghari Oskoei & Hu, 2007). Como se muestra en la Figura 2.8, en la técnica de las ventanas adyacentes la señal se divide en segmentos de una longitud predefinida, y el intento de clasificación de ese segmento viene dado después de un tiempo de procesamiento. La técnica de ventanas traslapadas, se toma un segmento de una longitud predefinida, después de un tiempo de traslape se toma un nuevo

segmento que esta traslapado en algunos datos con el segmento anterior, el tiempo de traslape debe ser menor al tiempo de procesamiento, debido a que el procesador debe realizar ciertas tareas de procesamiento previo a generar una decisión y antes de que llegue el siguiente segmento a procesar.




Figura 2.8 Técnica de segmentación de ventanas: a) adyacentes, y b) traslapadas.

2.3.2 Extracción de características

Las características de una señal sEMG son extremadamente dependientes del nivel y la duración de la contracción muscular, los estados estático y dinámico del musculo, la fatiga y la humedad de la piel (*Asghari Oskoei & Hu, 2007*), es por esa razón que la aleatoriedad de la señal hace que el análisis de los datos naturales en el tiempo sea impráctico, es por esa razón que la estrategia que se utiliza para la clasificación de señales sEMG es la extracción de características que ayuden a identificar patrones. De acuerdo con (*Zecca et al., 2002*) hay tres tipos de características principales para el control de sistemas EMG: en el dominio del tiempo (TD); directamente relacionada con la amplitud de la señal, en el dominio de la frecuencia (FD); relacionadas al espectro de potencia de la señal, y en el dominio del tiempo-frecuencia (TD-FD); analizadas mediante herramientas de la transformada wavelet.

2.3.2.1 Características en el dominio del tiempo

Las características extraídas en el dominio del tiempo (TD) son las más populares para el reconocimiento de patrones en señales sEMG, debido a que son fáciles y rápidas de calcular, y además no requieren ninguna transformación, por lo que el tiempo de cómputo es menor comparado con otro tipo de características, lo cual es de suma importancia debido a las aplicaciones de este tipo de sistemas. Este tipo de características son computadas basadas en su amplitud y los valores resultantes dan una medida de la amplitud, la frecuencia y la duración de la forma de onda dentro de unos parámetros limitados (*Oskoei & Hu, 2006*). Ejemplos de características TD son: media del valor absoluto (MAV), raíz cuadrada media (RMS), longitud de onda (WL), etc. las ecuaciones de estas y más características en el tiempo pueden observarse en el Apéndice B.

2.3.2.2 Características en el dominio de la frecuencia

Las características extraídas en el dominio de la frecuencia (FD) se basan en la estimación del espectro de densidad de potencia (PSD) y se calculan mediante el periodograma o métodos paramétricos, aunque estas, en comparación de las características TD, requieren más tiempo de cómputo (*Oskoei & Hu, 2006*), debido a que se requiere el cálculo de la transformada de Fourier. Este tipo de características más comúnmente utilizadas para el estudio de la fatiga muscular y el análisis de reclutamiento de MUs (*Phinyomark et al., 2012*). Ejemplos de características FD son: media de la frecuencia (MNF), mediana de las frecuencias (MDF), frecuencia pico (PKF), etc. las ecuaciones de estas y más características en frecuencia pueden observarse en el Apéndice B.

2.3.2.3 Características en el dominio del tiempo-frecuencia

Las características extraídas en el dominio del tiempo-frecuencia (TD-FD) describen como el espectro de potencia varía en el tiempo, para este tipo de características la transformada Wavelet es la más utilizada. La transformada Wavelet puede ser dividida en su forma continua y discreta, lo que transforma la señal de forma eficiente dándole una resolución flexible en los dominios del tiempo y de la frecuencia. A pesar de que el análisis pudiera parecer más profundo, las características TD han mostrado tener mejores rendimientos al momento de clasificar patrones con señales sEMG comparándolas con TD-FD e incluso con las características FD (*L. J. Hargrove et al., 2007*).

2.3.2.4 Características del espectro de potencia extraídas en el tiempo

Otra alternativa para extraer características que ha dado buenos rendimientos al clasificar señales sEMG es analizar el PSD en el dominio del tiempo mediante el cálculo de los momentos de la misma función PSD, por ejemplo, como se mencionó en los antecedentes, (*Pancholi et al., 2021*) utilizaron dos características (TD-PSD1) derivadas del espectro de potencia para entrenar una red CNN, mejorando las precisiones logradas en las bases de datos DB1, DB2 y DB3, y demostrando también que utilizando este tipo de características estabiliza la señal y se reduce el tiempo de entrenamiento de la red debido a la cantidad de características utilizadas. Por otro lado, (*Khushaba et al., 2012*) utilizaron cinco características también derivadas del espectro PSD para demostrar que se reduce la variabilidad del error en la clasificación de este tipo de señales al modificar la posición de la extremidad. Estas características fueron obtenidas del teorema de Parseval, el cual establece que la suma del cuadrado de una función es igual a la suma del cuadrado de su transformada de Fourier, y está dado por:

$$\sum_{j=0}^{N-1} |x[j]|^2 = \frac{1}{N} \sum_{k=0}^{N-1} |X[k]X^*[k]| = \sum_{k=0}^{N-1} P[k] \quad (1)$$

Además, esto es igual a la suma de las amplitudes del espectro de potencia $P[k]$, donde k es el índice de frecuencia, $X[k]$ es la señal sEMG expresada como una función de la frecuencia, y $X^*[k]$ es su conjugado obtenido a través de la transformada discreta de Fourier (DFT). Debemos considerar que la descripción completa de la transformada de Fourier es simétrica respecto a la frecuencia cero y que debido a esto y al factor de que desde el dominio del tiempo no podemos acceder al espectro PSD, el análisis en el dominio del tiempo debe incluir el espectro entero, considerando las frecuencias positivas y negativas, consecuentemente, de acuerdo a la definición de un momento m de orden n del espectro $P[k]$ el cual está dado por:

$$m_n = \sum_{k=0}^{N-1} k^n P[k] \quad (2)$$

Nosotros podemos definir los momentos impares como cero desde una aproximación estadística a la forma de distribución de la frecuencia. Así que, con la ecuación 2, nosotros podemos usar el teorema de Parseval para calcular el momento m_0 como:

$$m_0 = \sum_{k=0}^{N-1} k^0 P[k] = \sum_{j=0}^{N-1} |x[j]|^2 \quad (3)$$

El cual es un indicador del total de potencia en el dominio de la frecuencia. Para calcular el resto de momentos, podemos usar la propiedad de la diferenciación del tiempo de la transformada de Fourier, el cual dice que la n th derivada de una función en TD (Δ^n) para señales discretas en el tiempo es equivalente a multiplicar el espectro $X[k]$ por la k elevado a la n th potencia.

$$\mathcal{F}[\Delta^n x[j]] = k^n X[k] \quad (4)$$

Considerando esta propiedad, el momento m_2 puede ser obtenido por:

$$m_2 = \sum_{k=0}^{N-1} k^2 P[k] = \sum_{k=0}^{N-1} (k^n X[k])^2 = \sum_{j=0}^{N-1} (\Delta x[j])^2 \quad (5)$$

En el mismo camino el momento m_4 puede ser calculado por:

$$m_4 = \sum_{k=0}^{N-1} k^4 P[k] = \sum_{j=0}^{N-1} (\Delta^2 x[j])^2 \quad (6)$$

Entonces, las características propuestas por ellos, las cuales denotaremos a partir de ahora como TD-PSD2, son derivadas del cálculo de los momentos m_0 , m_2 y m_4 , las cuales son detalladas en la Tabla 2.2.

Tabla 2.2 Descripción de las 5 características TD-PSD2.

Característica	Ecuación	Descripción
f_1	$\log(m_0) \quad (7)$	Indicador del total de potencia en el dominio de la frecuencia
f_2	$\log(m_2/m_0^2) \quad (8)$	Estabilizador de ruido
f_3	$\log(m_4/m_0^2) \quad (9)$	Estabilizador de ruido
f_4	$\log\left(\frac{m_0}{\sqrt{m_0 - m_2} * \sqrt{m_0 - m_4}}\right) \quad (10)$	Indicador de cuanta energía de un vector esta acumulada en pocos elementos
f_5	$\log\left(\frac{\sqrt{\frac{m_2^2}{m_0 * m_4}}}{WL}\right) \quad (11)$	Factor de irregularidad dentro de una longitud de onda definida

2.3.3 Clasificación

La clasificación de patrones en señales mioeléctricas es uno de los principales retos en el área de las aplicaciones con este tipo de señales. El método que ha dado mejores resultados, es el utilizar las características extraídas de las señales para entrenar algoritmos de machine learning y deep learning, Existen varios tipos de clasificadores que se han utilizado eficientemente para diferentes aplicaciones de sEMG, como las redes neuronales artificiales (ANN), clasificador difuso, análisis discriminante lineal (LDA), Mapa auto organizado (SOM), máquinas de soporte de vectores (SVM) (*Chowdhury et al., 2013*), y más recientemente las redes neuronales convolucionales, debido a que esta última y las ANN han sido las más utilizadas en la literatura, en este trabajo decidimos utilizar ambas para comparar nuestros resultados.

2.3.3.1 Redes neuronales Artificiales (ANN)

Las redes ANN han sido ampliamente utilizadas para la clasificación mioeléctrica, debido a que una de sus principales ventajas es su habilidad de representar relaciones tanto lineales como no lineales; y aprender estas relaciones directamente de los datos que están siendo modelados (*Asghari Oskoei & Hu, 2007*).

Las ANN son modelos computacionales inspirados en el sistema nervioso de los seres vivos. Este tipo de redes tienen la capacidad de adquirir y mantener información y pueden definirse como un conjunto de unidades de procesamiento, presentadas como neuronas artificiales, conectadas por varias interconexiones (sinapsis artificial) (da Silva et al., 2017), interconexiones que son alteradas por pesos sinápticos.

2.3.3.1.1 Neurona biológica

Una neurona biológica recibe señales a través de las dendritas de la membrana mediante la sinapsis, cuando la señal recibida es lo suficientemente grande (superando un cierto umbral), la neurona es activada y emite una señal a través de su axón, esta señal puede ser enviada a otra sinapsis y puede activar otras neuronas (Ver Figura 2.9), entonces, las señales se transmiten entre neuronas mediante potenciales de acción, que tienen un perfil estereotípico y muestran un carácter de “todo o nada” al superar un umbral de diferencia de potencial (Gurney, 2004).




Figura 2.9 Transmisión de señal de una neurona biológica.

2.3.3.1.2 Neurona artificial

Las neuronas artificiales, las cuales son el elemento fundamental de las redes neuronales artificiales, están inspiradas en el modelo de una neurona biológica y cómo es que funciona el sistema nervioso y el cerebro mismo al momento de transmitir información. El modelo más simple de una neurona artificial lo

propusieron (McCulloch & Pitts, 1943), y sigue siendo el más utilizada en la actualidad en arquitecturas de redes neuronales artificiales.

La Figura 2.10 muestra el modelo de una neurona artificial, donde por un lado puede tener múltiples entradas provenientes de un ambiente externo, las cuales son representadas por $\{x_1, x_2, \dots, x_n\}$, y que es análogo a los impulsos eléctricos provenientes de otras neuronas en el modelo de neuronas biológicas, cada una de esas entradas es multiplicada por un peso sináptico $\{w_1, w_2, \dots, w_n\}$, que es análogo a la relevancia que tiene cada entrada de una neurona biológica respecto a su salida, entonces, la salida de cada neurona artificial es la sumatoria de todas estas multiplicaciones más un sesgo (θ), que es una variable utilizada para especificar un umbral adecuado que debe tener la salida de la sumatoria para generar un valor de activación hacia la salida de la neurona (da Silva et al., 2017), la salida de la sumatoria esta denotada en la Figura 2.10 como u .

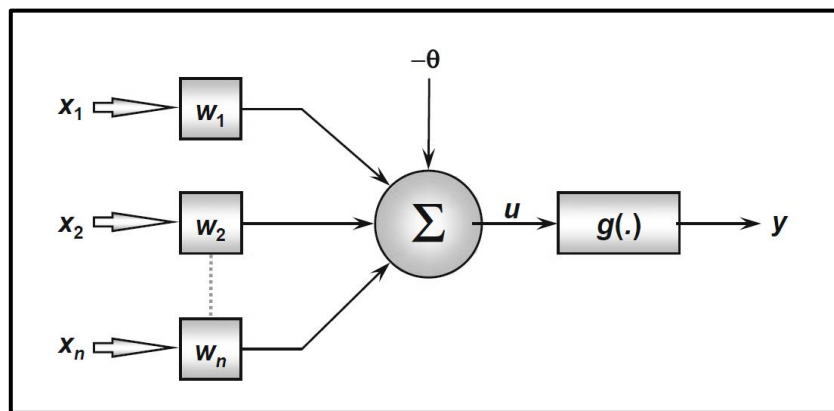


Figura 2.10 Neurona artificial

La sumatoria entonces está definida como:

$$u = \sum_{i=1}^n w_i * x_i - \theta \quad (12)$$

Después esa sumatoria es evaluada en una función de activación (g) cuyo objetivo es limitar la salida de la neurona dentro de un rango de valores

definidos, esta función de activación dará la salida de la neurona artificial (y), la cual puede ser utilizada como entrada de otra u otras neuronas interconectadas, o bien puede ser la salida de toda la estructura neuronal. Entonces, la salida de cada neurona está definida como:

$$y = g(u) \quad (13)$$

Un ejemplo de función de activación neuronal es la función sigmoidea logarítmica cuya expresión matemática está dada por:

$$g(u) = \frac{1}{1 + e^{-\beta * u}} \quad (14)$$

Donde β es una constante real asociada a la pendiente de la función en su punto de inflexión. La respuesta de esta función siempre es un valor real entre cero y uno, su comportamiento puede observarse con mayor claridad en la Figura 2.11.

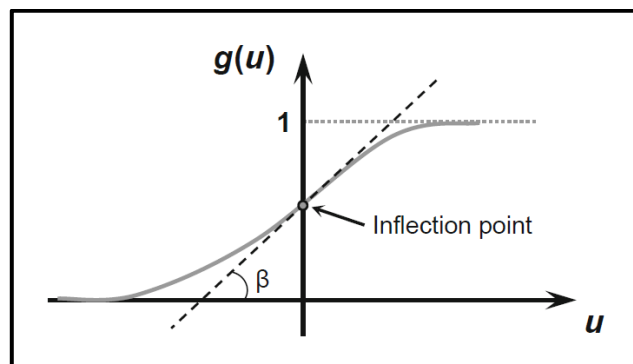


Figura 2.11 Función de activación Sigmoidea logarítmica (da Silva et al., 2017).

2.3.3.1.3 Arquitectura neuronal artificial

Las arquitecturas de redes neuronales artificiales, están compuestas por neuronas artificiales interconectadas unas con otras en diferentes capas, y en lo general pueden dividirse en tres partes, primero está la capa de entrada, que es la capa donde se conectan las entradas de la red (datos, señales, características, mediciones de algún proceso, etc.), la normalización de estos

datos de entrada en los límites de operación de las funciones de activación mejora el rendimiento de la red. Después viene la capa o capas ocultas, a estas capas también se les conoce como de “extracción de características” debido a que la salida de estas capas está asociada a patrones en el proceso o sistema que está siendo analizado. Y por último esta la capa de salida, que es la encargada de arrojar un resultado en función del procesamiento de todas las capas previas, la Figura 2.12 muestra un ejemplo de una estructura neuronal de una red feedforward (flujo de datos hacia adelante) con una capa de entrada, dos ocultas y una capa de salida.

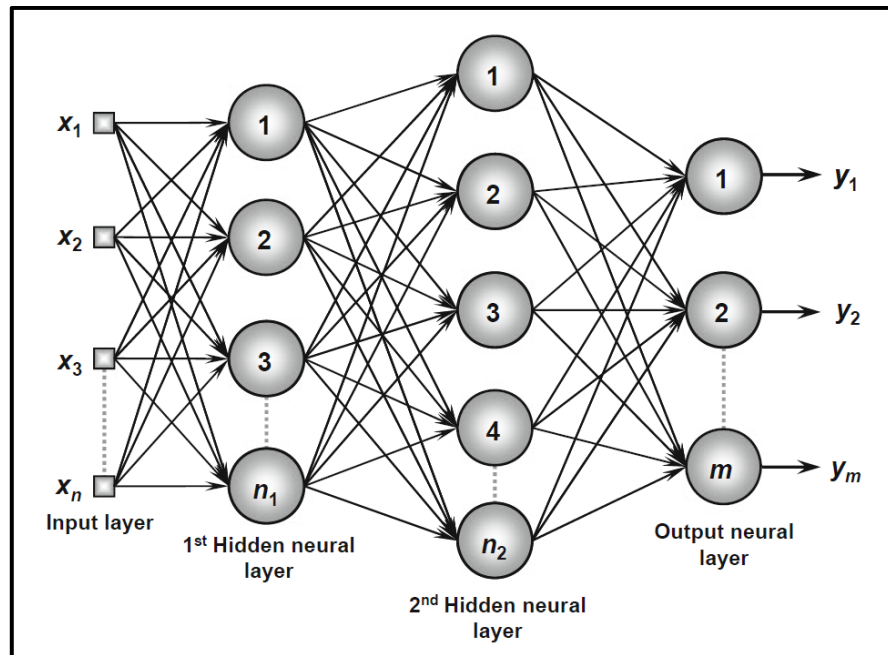


Figura 2.12 Ejemplo de red neuronal de múltiples capas (da Silva et al., 2017).

2.3.3.1.4 Proceso de entrenamiento de una red neuronal artificial multicapa

Para el entrenamiento de una red neuronal artificial de varias capas, se debe seguir un proceso en dos partes, la primera parte consisten en avanzar hacia adelante en la red mientras calculamos las salidas de cada neurona hasta encontrar la respuesta de la red a los datos de entrada, a ese proceso se le

llama propagación hacia adelante (forward propagation) y se realiza para cada una de las muestras que se utilicen para el entrenamiento. En la Figura 2.13 puede observarse una neurona la cual sus pesos sinápticos están determinados por W_{ji}^L , donde j representa el número de neurona de la capa L , e i representa el número de entrada de la neurona j .

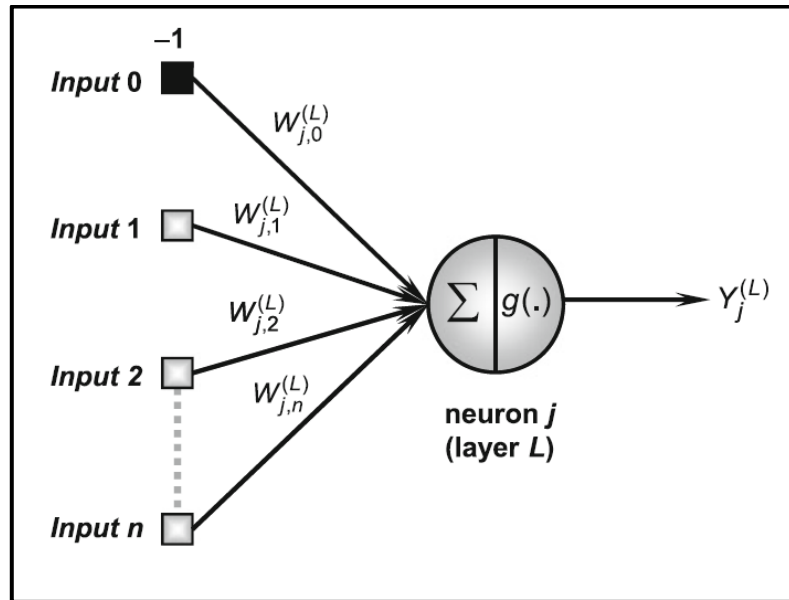


Figura 2.13 Modelo de neurona j en una capa L.

La sumatoria de cada neurona I_j^L será la sumatoria de los pesos multiplicados por sus respectivas entradas, por ejemplo para la capa 1, la sumatoria de la neurona 1 sería:

$$I_j^{(1)} = \sum_{i=0}^n W_{ji}^{(1)} * x_i \leftrightarrow I_j^{(1)} = W_{j0}^{(1)} * x_0 + W_{j1}^{(1)} * x_1 + \dots + W_{jn}^{(1)} * x_n \quad (15)$$

Y la salida de cada neurona estará determinada por Y_j^L , es decir, la respuesta de la sumatoria I_j^L al pasarla por la función de transferencia g

$$Y_j^L = g(I_j^L) \quad (16)$$

El siguiente paso es calcular el error del modelo mediante una función denominada función de coste, cuyo propósito es el de medir el error de nuestras salidas calculadas con respecto a las salidas que deseamos. La función de coste más común es la función del error cuadrático medio, el cual se calcula para cada uno de los datos de entrenamiento k , la sumatoria de todos los errores estará definida por:

$$E(k) = \frac{1}{2} \sum_{j=1}^n (d_j(k) - Y_j(k))^2 \quad (17)$$

Donde $Y_j(k)$ es el valor de salida de la neurona j de la capa de salida para la muestra de entrenamiento k , $d_j(k)$ es el valor deseado de esa misma neurona y n es el número de neuronas en la capa de salida. El error cuadrático medio estará definido entonces por:

$$E_M = \frac{1}{p} \sum_{k=1}^p E(k) \quad (18)$$

Asumiendo que p es el número de muestras utilizadas para entrenar la arquitectura.

2.3.3.1.5 Entrenamiento de la red neuronal

El aprendizaje de las redes neuronales involucra el ajuste de los pesos buscando minimizar el error (*Hristev, 1998*), el algoritmo más común para hacer este ajuste es el de propagación hacia atrás (backpropagation) calculando el gradiente de la función del error (∇E) y aplicándola regla de la cadena para derivaciones:

$$\nabla E^L = \frac{\partial E}{\partial W_{ji}^L} = \frac{\partial E}{\partial Y_j^L} * \frac{\partial Y_j^L}{\partial I_j^L} * \frac{\partial I_j^L}{\partial W_{ji}^L} \quad (19)$$

Entonces, realizando las derivadas correspondientes, el ajuste de la matriz de pesos de cada capa W_{ji}^L esta dado por

$$W_{ji}^L(t + 1) = W_{ji}^L(t) - \eta \frac{\partial E}{\partial W_{ji}^L} \quad (20)$$

Donde η es una variable denominada como tasa de aprendizaje del algoritmo de backpropagation, y es utilizada para modificar la velocidad y la calidad del proceso de entrenamiento de la red. Este ajuste de pesos, se realiza cada vez que se introducen nuevos datos de entrenamiento.

2.3.3.2 Redes neuronales convolucionales (CNN)

En los años más recientes hemos visto un dramático crecimiento en el rendimiento de sistemas de reconocimiento debido a la introducción de arquitecturas profundas para el aprendizaje de características y clasificación (*Sewak et al., 2018*). Las redes neuronales convolucionales (CNN) son el algoritmo más utilizado para este tipo de aplicaciones debido a sus altos rendimientos, las redes convolucionales son redes neuronales que utilizan la convolución en lugar de una multiplicación general matricial en al menos una de sus capas (*Goodfellow et al., 2016*).

A diferencia de las redes neuronales artificiales, las convolucionales se basan en el hecho de aplicar una serie de convoluciones a imágenes que son la entrada de la red. En términos generales, una estructura de red neuronal convolucional puede dividirse en dos partes, como se muestra en la Figura 2.14, una compuesta por capas convolucionales conocida como “extracción de características”, y otra donde se hace pasar el resultado de la extracción de características por una red neuronal artificial común con neuronas totalmente conectadas. La intención de aplicar este tipo de redes es identificar características en las imágenes y lograr clasificarlas con la mayor eficiencia posible.

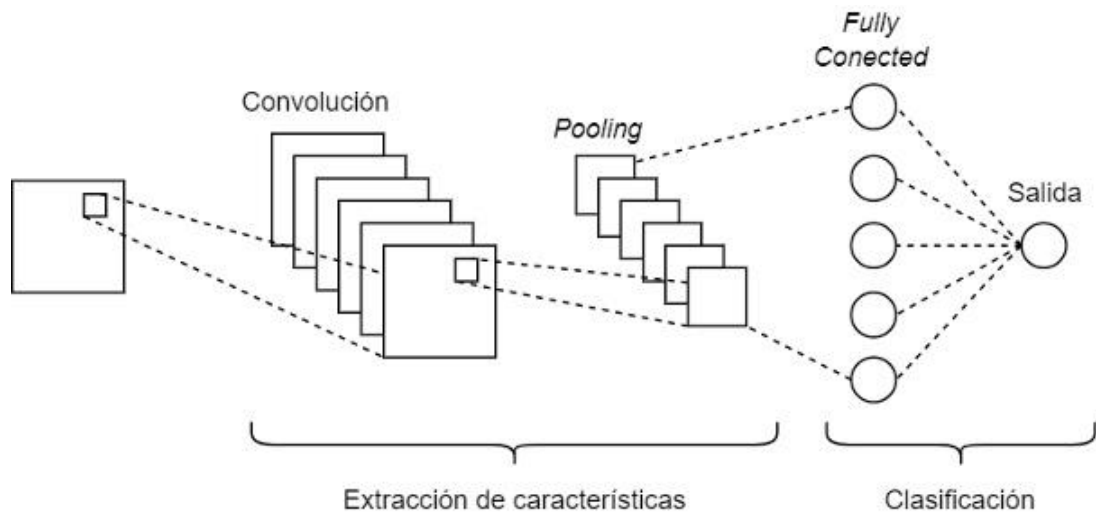


Figura 2.14. Estructura general de una red neuronal convolucional

2.3.3.2.1 Convólución

La convólución es una operación matemática entre dos funciones en la que el resultado es una tercera función ($s(t)$) que en cierto sentido representa una ponderación de la primera función ($x(a)$) al hacerle pasar la segunda función invertida ($w(t - a)$), y está dada por:

$$s(t) = \int x(a)w(t - a)da \quad (21)$$

El operador de la convólución es típicamente un asterisco

$$s(t) = (x * w)(t) \quad (22)$$

Dentro de la terminología utilizada para CNN el primer argumento de la convólución se refiere a la entrada y al segundo argumento se le refiere como “kernel” (también llamado filtro en ocasiones), mientras que al resultado de la operación se le conoce como mapeo de características. Cuando trabajamos con procesamiento digital es necesario tomar a la convólución como una operación discreta, en ese sentido se puede volver a definir como:

$$s(t) = \sum_{-\infty}^{\infty} x(a)w(t - a) \quad (23)$$

Donde t puede tomar únicamente valores enteros.

Las redes CNN comúnmente trabajan con imágenes como sus entradas, es decir 2 dimensiones, por lo que podemos redefinir la operación de la convolución con una entrada I de dos dimensiones convolucionada con un kernel K también de dos dimensiones:

$$s(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n)K(i - m, j - n) \quad (24)$$

En el caso de las redes CNN comúnmente se implementa una correlación cruzada (cross-correlation) la cual es lo mismo que la convolución pero sin invertir el kernel:

$$s(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i + m, j + n)K(m, n) \quad (25)$$

Muchas librerías de machine learning implementan esa correlación pero le llaman convolución (*Goodfellow et al., 2016*), esto se debe a que usualmente en las redes CNN no es importante la propiedad de una convolución de ser conmutativa, y resulta más cómodo que al final de la fase de entrenamiento, los kernels cuyos pesos se han modificado y que ha aprendido la red no estén invertidos.

2.3.3.2.2 Capa convolucional

La parte de la CNN donde se realizan las convoluciones está compuesta por varias capas, en cada una de estas capas convolucionales se aplican una serie de kernels a las imágenes de entrada de la red, posteriormente el resultado se hace pasar por una función de activación conocida como RELU (Rectified

Lineal Unit), la cual permite un acotamiento de los datos de salida, esta parte de la red es conocida en ocasiones como estación de detección.

2.3.3.2.3 Pooling

En cada capa convolucional usualmente se aplica una función llamada “pooling” previo a ser pasada por la capa siguiente, esta función reemplaza la salida de la capa con una estadística de resumen de las salidas cercanas (*Goodfellow et al., 2016*), esta función ayuda a reducir en gran medida la cantidad de datos de la red que se van pasando de capa en capa, conservando la mayor cantidad de información posible, dentro de las funciones de pooling más utilizadas se encuentra el “max pooling”, el cual consiste en tomar el valor máximo en pequeñas ventanas o regiones de las imágenes resultantes de las convoluciones de la capa previa, por ejemplo, si aplicamos un max pooling de 2x2 a una imagen de 4x4 el resultado será una imagen de 2x2, ya que la imagen original será dividida en 4 regiones de 2x2 y el valor del pixel más alto será el que represente a esa región en la nueva imagen de 2x2.

CAPITULO 3. METODOLOGÍA

El presente capítulo se divide en 2 partes, en un principio se tenía la intención de implementar una metodología que nos permitiera adquirir nuestras propias señales y con ellas evaluar el rendimiento de los diferentes métodos de clasificación, sin embargo, y por motivos de salud derivados de la pandemia que paralizó al mundo en el año 2019, se optó por no interactuar con personas y el lugar de eso utilizar una base de datos pública. Por lo tanto, la primera parte de este capítulo describe la metodología seguida para crear un sistema de adquisición de 6 canales sEMG, y la segunda parte describe la metodología a seguir para la clasificación de señales partiendo de una base de datos ya generada.

3.1 Metodología para la adquisición de señales sEMG propias

La **¡Error! No se encuentra el origen de la referencia.** muestra la metodología a seguir para llevar a cabo el grabado de señales sEMG, contemplando la colocación de los electrodos, el acondicionamiento y la adquisición de la señal.

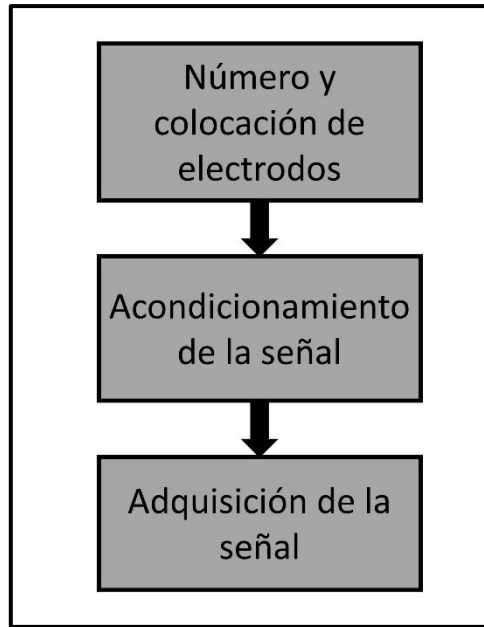


Figura 3.1 Diagrama para el grabado de señales mioeléctricas.

3.1.1 Número y colocación de electrodos

En un estudio (A. H. Al-Timemy et al., 2013) evaluaron el rendimiento al clasificar 15 y 12 movimientos de dedos en personas no amputadas y personas amputadas respectivamente, modificando el número de canales de adquisición en configuración bipolar desde uno hasta 12, demostrando que no había diferencia significativa en el rendimiento a partir de los seis canales en adelante, por esa razón, en este trabajo se decidió utilizar seis canales de adquisición en configuración bipolar. Los canales fueron colocados alrededor del antebrazo de cada persona, colocando el electrodo inicial en el musculo

braquiorradial a 1/3 de su longitud partiendo de la parte superior (Ver Figura 3.2a), y el resto distribuidos de manera uniforme alrededor y paralelos al primero (Ver Figura 3.2b), cada uno de los cuales consta de un par de electrodos de plata cloruro de plata (Ag/AgCl) autoadhesivos.

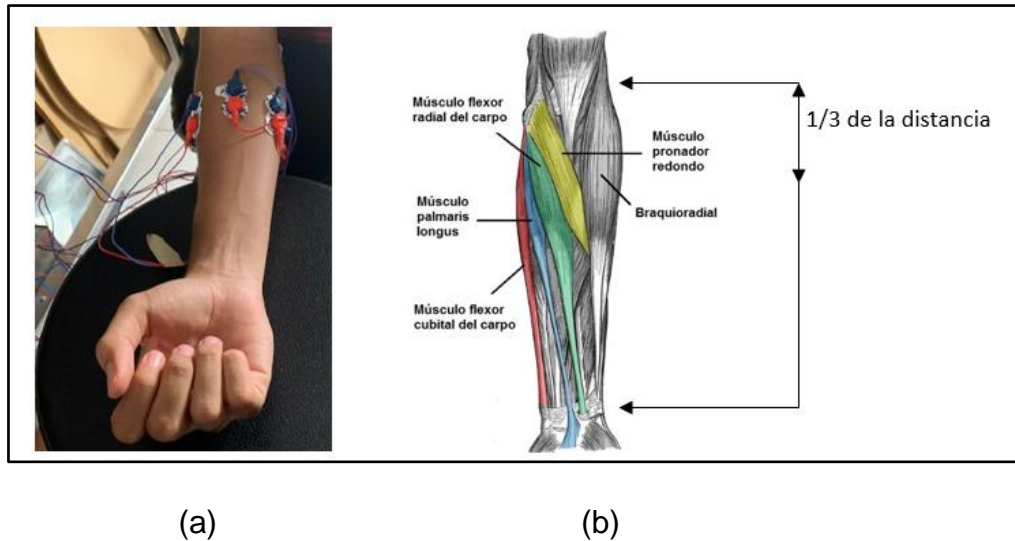


Figura 3.2 a) Colocación de los 6 canales sEMG, b) Distancia para la colocación del primer electrodo.

Para reproducir la posición de los electrodos entre persona y persona se siguieron las recomendaciones europeas para la adquisición de señales sEMG (*Freriks & Hermens, 1999*), entre las cuales se encuentran que: la zona donde se colocan los electrodos debe ser afeitada y limpiada con alcohol, la persona deberá estar sentada cómodamente con el codo flexionado en un ángulo de 90° con respecto a la vertical, y con la posición posterior del antebrazo viendo hacia abajo (Ver Figura 3.3), la distancia entre electrodos del mismo canal deberá ser de 20mm y la orientación de los electrodos deberá ser paralelos a la orientación de las fibras musculares.



Figura 3.3 Posición del cuerpo para la adquisición de una señal sEMG del antebrazo.

3.1.2 Acondicionamiento de la señal

La señal obtenida de los electrodos, la cual tiene una amplitud aproximada de $\pm 5000 \mu\text{V}$ (Konrad, 2005), se amplificó 1000 veces con la ayuda de un amplificador de instrumentación previo a su adquisición para obtener un rango de $\pm 5 \text{ V}$. Además, debido a que el 95% de los armónicos de la señal se encuentran arriba de los 400 Hz y que la inestabilidad de la interface piel-electrodo genera ruidos en frecuencias por debajo de los 20 Hz, se implementó un filtro pasa banda de 20 a 500 Hz de 4to orden según lo recomiendan (Coughlin & Driscoll, 1993) para señales en este rango de frecuencias (Ver Figura 3.4). Además, de forma digital se implementó una segunda estación de filtrado, con un filtro pasa banda de 20 a 400 Hz y un filtro rechaza banda en los 60 Hz, para evitar ruidos provenientes del suministro eléctrico.

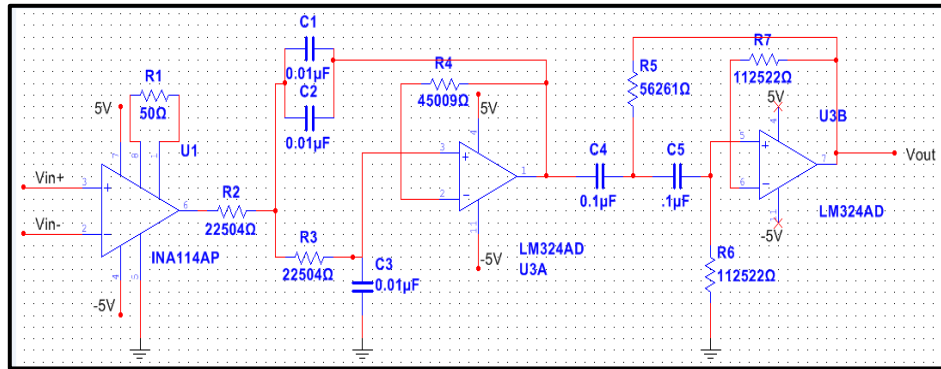


Figura 3.4 Circuito amplificador a mil veces y filtro pasa banda de 4to orden de 20 a 500 Hz, para un canal de adquisición de señal sEMG.

3.1.3 Adquisición de la señal

Para la adquisición de las señales EMG se utilizó una tarjeta de adquisición de la marca ADVANTECH Modelo USB-4716 (Ver. Figura 3.5), la cual cuenta con 6 canales análogos de entrada diferenciales con una resolución de 16 bits a un voltaje de +/- 5V. Debido al rango de frecuencias de interés, la señal se muestrea a 2000 Hz, y fueron visualizadas en el software LabVIEW de la plataforma National Instruments.



Figura 3.5 Tarjeta de adquisición de la marca ADVANTECH modelo USB 4716.

3.2 Metodología para clasificación de señales sEMG desde una base de datos existente

De acuerdo al procedimiento descrito en la sección anterior, era necesario interactuar con personas dispuestas a contribuir con el procedimiento experimental de la colocación de los electrodos y el grabado de las señales sEMG, lamentablemente no se pudo continuar con el proceso anterior debido a la pandemia de COVID que se suscitó en el año 2019, por lo que decidimos utilizar una base de datos publica y continuar con el procedimiento experimental partiendo de las señales obtenidas.

3.2.1 Descripción de Base de datos NINA PRO

La base de datos NINA (Prótesis de mano adaptativa no invasiva, por sus siglas en inglés) PRO, es una base de datos multimodal desarrollada por *(Atzori, Gijsberts, Castellini, et al., 2014)*, la cual está disponible públicamente con la intención de fomentar la investigación en prótesis de mano robóticas controladas con inteligencia artificial. Este repositorio, además de datos de electromiografía, también incluye otros datos relacionados con cinemática, inercia, seguimiento de ojo, visual clínicos y neurocognitivos, que son usados a lo largo del mundo por investigadores en robótica, machine learning, ciencias médicas y neurocognitivas.

Las base de datos utilizada en este proyecto, fueron las definidas como DB2 y DB3, las cuales tienen información de señales extraídas de 40 sujetos con las extremidades intactas y de 11 sujetos con una amputación trasradial respectivamente, los resultados con sujetos intactos pueden ser usados como una medida aproximada para sujetos que tienen algún tipo de amputación *(Atzori, Gijsberts, Muller, et al., 2014)*, sin embargo, y como se mencionó en los objetivos de este proyecto, es importante la comprobación del algoritmo también con personas con algún tipo de amputación trasradial, ya que ellos serán los usuarios finales de la implementación de este tipo de tecnología.

3.2.1.1 Participantes

La base de datos DB2 contiene información de 40 sujetos intactos, de los cuales 28 son del sexo masculino y 12 del sexo femenino, 34 son diestros y 6 son zurdos, y están entre edades de 29.9 ± 3.9 años. La base DB3 contiene información de 11 sujetos con algún tipo de amputación trasradial, los 11 son del sexo masculino, de los cuales 10 son diestros y uno es zurdo, y están entre edades de 42.36 ± 11.96 años.

Antes del procedimiento de adquisición de las señales, a cada persona se le requirió el dar su consentimiento y contestar algunas preguntas, las cuales incluyen: edad, genero, altura, peso y lateralidad (diestros o zurdos), en el caso de los amputados también se tomó nota de la fecha, tipo y razón de su amputación trasradial, porcentaje restante del antebrazo, información acerca de uso de algún tipo de prótesis (cosmética, cinemática, mioeléctrica), tipo y grado de sensación de extremidad fantasma y el score DASH (Discapacidad del brazo, hombro y mano, por sus siglas en ingles), el cual es un cuestionario de 78 preguntas el cual tiene como objetivo dar una medida de los síntomas y el estatus funcional (*Hudak et al., 1996*), entre más alto sea el puntaje obtenido mayor es su discapacidad. La información completa de los participantes de la base de datos se encuentra en el Apéndice A de este documento.

El experimento fue conducido de acuerdo a los principios expresados en la declaración de Helsinki y fue aprobado por la comisión de ética de Cantón del Valais (Suiza).

3.2.1.2 Colocación y número de electrodos

Las señales mioeléctricas fueron recabadas utilizando 12 electrodos Delsys Trigno inalámbricos (Delsys s.f.) En configuración bipolar, los electrodos fueron posicionados como se muestra en la Figura 3.6, ocho de los cuales se colocaron igualmente espaciados alrededor del antebrazo a la altura de la

unión entre el radio y el humero, dos electrodos más fueron puestos en los puntos de mayor actividad de los músculos flexores y extensores de los dedos, y los últimos dos fueron colocados en los puntos de mayor actividad del bíceps y el tríceps. Las ubicaciones se eligieron con la finalidad de combinar dos enfoques distintos; el muestreo denso (F. V. G. Tenore *et al.*, 2009) y el posicionamiento anatómico preciso (C. J. De Luca, 1997).

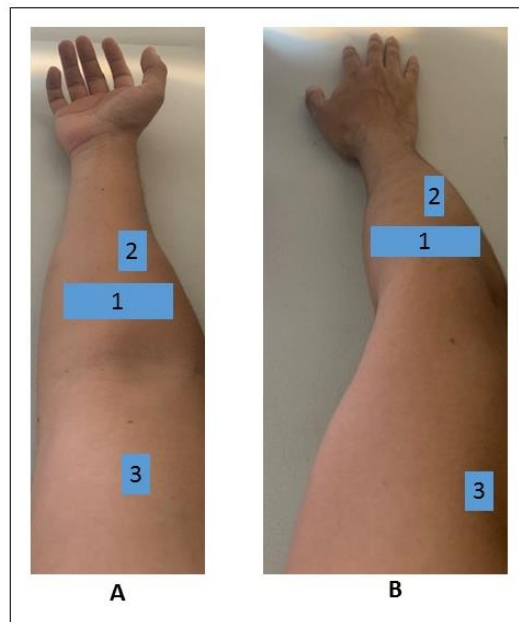


Figura 3.6 Colocación de electrodos, A.1 y B.1 Electrodo igualmente espaciados, A.2 electrodo en músculos flexores de los dedos, A.3 electrodo en el bíceps, B.2 electrodo en músculos extensores de los dedos, B.3 electrodo en el tríceps.

3.2.1.3 Descripción de los movimientos

Para la base de datos 2 y 3 de NINA se recabaron señales de 50 movimientos (contemplando el reposo) los cuales fueron seleccionados de la literatura de la taxonomía de mano, la robótica y la rehabilitación de mano, con el propósito de cubrir la mayoría de los movimientos de mano que una persona podría requerir en las actividades de la vida diaria, los movimientos están divididos en 3 grupos más el reposo, el reposo se considerara como el movimiento 1, del 2 al 18 son movimientos básicos de dedos y de la muñeca: 2. Pulgar arriba,

3. Extensión del índice y medio, todos los demás flexionados, 4. Flexión del anular y menique, 5. pulgar flexionado hacia la base del menique, 6. Abducción de todos los dedos, 7. Dedos flexionados en puño, 8. Señalar con el índice, 9. Aducción de los dedos extendidos , 10. Supinación de la muñeca con eje en el dedo medio, 11. Pronación de la muñeca con eje en el dedo medio, 12. Supinación de la muñeca con eje en el dedo menique, 13. Pronación de la muñeca con eje en el dedo menique, 14. Flexión de la muñeca, 15. Extensión de la muñeca, 16. Desviación radial de la muñeca, 17. Desviación cubital de la muñeca y 18. Extensión de la muñeca con el puño cerrado, del movimiento 19 al 41 son movimientos funcionales y de agarre: 19. Agarre de diámetro grande, 20. Agarre de diámetro pequeño, 21. Agarre de gancho fijo, 22. Agarre con extensión del dedo índice, 23. Envoltura media, 24. Agarre de anillo (con dedo índice y pulgar), 25. Agarre prismático de 4 dedos, 26. Agarre de palo, 27. Agarre de escritura con 3 dedos, 28. Agarre de esfera con fuerza, 29. Agarre de esfera con 3 dedos, 30. Agarre de esfera con precisión, 31. Agarre con 3 dedos, 32. Agarre de pellizco prismático, 33. Agarre de pellizco de punta, 34. Agarre de 4 dedos, 35. Agarre lateral, 36. Agarre de extensión paralela, 37. Agarre tipo extensión, 38. Agarre de un CD con fuerza, 39. Abrir botella con 3 dedos, 40. Girar tornillo (agarre del destornillador con agarre de palo) y 41. Cortar algo (agarre del cuchillo con agarre de extensión del dedo índice), del movimiento 42 al 50 son movimientos de patrones de fuerza: 42. Flexión del dedo menique, 43. Flexión del dedo anular, 44. Flexión del dedo medio, 45. Flexión del dedo índice, 46. Abducción del pulgar, 47. Flexión del pulgar, 48. Flexión del dedo índice y el menique, 49. Flexión del dedo anular y el medio y 50. Flexión del dedo índice y pulgar. En la Figura 3.7 se pueden ver a detalle cada uno de los movimientos.

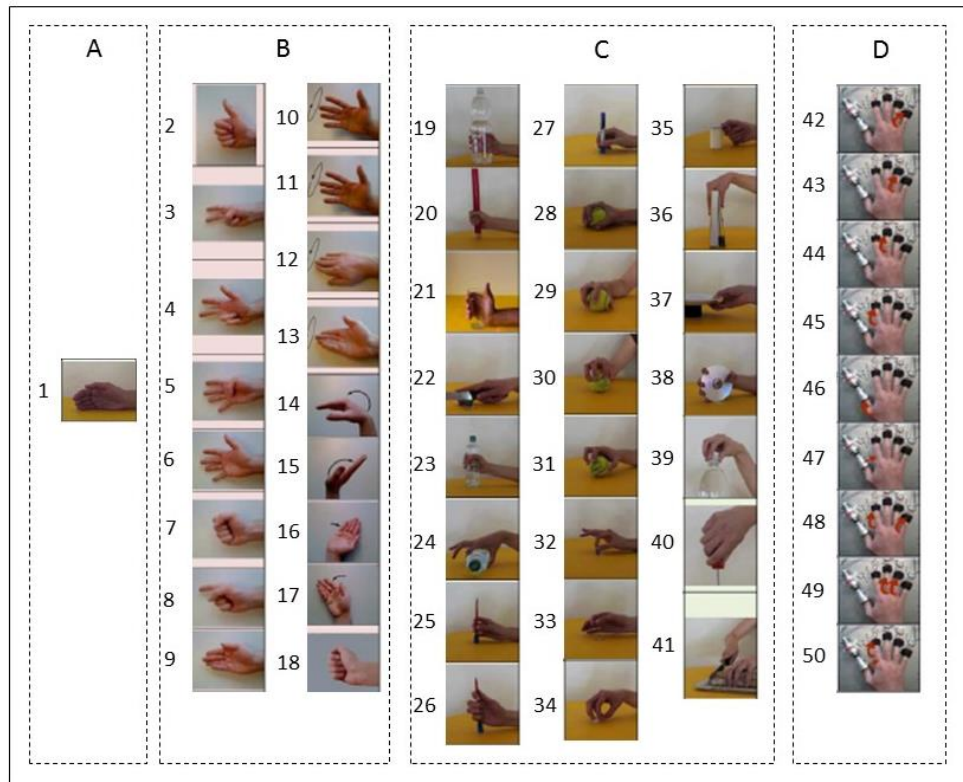


Figura 3.7 A. Reposo, B. Movimientos básicos de dedos y de la muñeca, C. Movimientos funcionales y de agarre, D. Patrones de fuerza (Atzori, Gijberts, Castellini, et al., 2014).

3.2.1.4 Acondicionamiento y adquisición de las señales

Los electrodos Delsys Trigno utilizados cuentan con una resolución de 16 bits a una tasa de muestreo de hasta 4370 muestras/segundo, para la adquisición de esta base de datos se utilizó una tasa de muestreo de 2khz, similar a la que se pretendía utilizar con las señales propias, el sensor cuenta con un filtro butterworth pasa banda de 40/80 dB/dec, dando la opción de seleccionar entre anchos de banda de 10 – 850 Hz y 20-420 Hz, para esta base de datos se utilizó el segundo, el rango de entrada de la señal EMG también puede seleccionarse de entre dos valores 11 mV y 22mV dependiendo de las necesidades del usuario.

Los electrodos no están protegidos contra interferencias de la línea de suministro eléctrico, el cual pudo haber afectado el grabado de las señales,

por lo tanto, al adquirirlas fueron filtradas utilizando un filtro Hampel (*Kuzborskij et al., 2012*) a 50 Hz.

Las señales fueron enviadas a una laptop mediante una red Wireless ad-hoc, que es un protocolo de comunicación inalámbrica descentralizada para evitar el tráfico del envío de múltiples canales a la vez.

3.2.1.5 Reetiquetado de la señal

Al realizar la adquisición de las señales, los movimientos realizados por los sujetos no siempre coincidían perfectamente con los estímulos propuestos por el software debido a los tiempos de reacción humanos y las condiciones experimentales. La base de datos contiene también un archivo llamado “Restimulos” que contiene la etiqueta de los movimientos corregidos aplicando un algoritmo de razón de probabilidad generalizado offline (*Kuzborskij et al., 2012*), de tal modo que, las señales sEMG de cada movimiento se pueden tomar con un mayor grado de certeza.

3.2.1.6 Protocolo experimental

Se les pidió a los sujetos que se sentaran frente a un escritorio en una silla de oficina ajustada a su mejor confort, y descansaran sus brazos sobre el escritorio. En frente de ellos se colocó una computadora que les proveía de estímulos visuales para cada tarea a realiza, mientras al mismo tiempo grababa los datos recabados por los sensores mioeléctricos (ver Figura 3.8).




Figura 3.8 Esquema del protocolo experimental. Los sujetos sentados frente a la pantalla de una computadora, donde pueden observar los movimientos y repetirlos.

Los sujetos repitieron 6 veces los 50 movimientos (considerando el reposo), cada una de las repeticiones con una duración de 5 segundos, alternada con 3 segundos de reposo para evitar la fatiga muscular, la secuencia de los movimientos no fue aleatoria, esto con la finalidad de estimular los movimientos repetitivos, casi inconscientes.

A los sujetos intactos se les pidió ejecutar el experimento con su mano derecha, mientras a los sujetos amputados se les pidió pensar en repetir los movimientos tan naturalmente como fuera posible con la extremidad faltante.

3.2.2 Clasificación de las señales sEMG

Para este trabajo se consideró analizar el rendimiento de la clasificación de gestos sobre la base de datos utilizando dos clasificadores: una red ANN y una red CNN, para ello se siguió el procedimiento de la Figura 3.9, donde específicamente para el clasificador ANN no es necesario el bloque de “Formación de imágenes”.

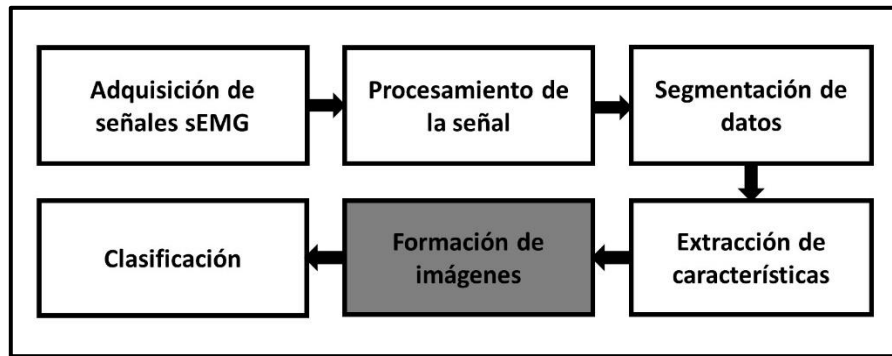



Figura 3.9 Diagrama de bloques para la clasificación de señales mioeléctricas.

El bloque de adquisición de señal está cubierto por la base de datos NinaPro descrita en la sección anterior.

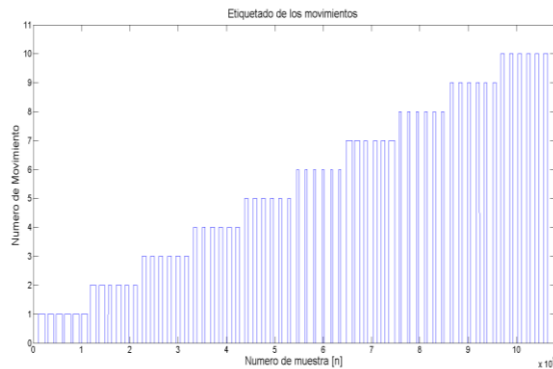
3.2.2.1 Procesamiento de la señal

Parte del procesamiento de la señal se realizó también en la adquisición de la base de datos, donde mediante los electrodos se filtraron y se amplificaron las señales mioeléctricas, además, para este trabajo se implementó una segunda estación de filtrado digital con un filtro pasa banda de decimo orden de 20 a 450 Hz para garantizar remover cualquier señal que no sea de interés.

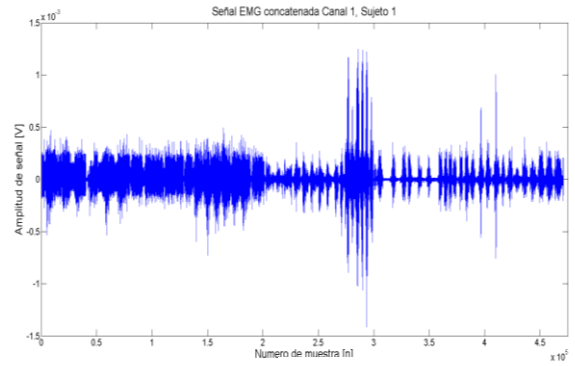
Debido a que las señales fueron adquiridas con un periodo de reposo entre cada repetición de los movimientos, es necesario concatenar los datos de cada repetición, con la finalidad de obtener muestras continuas y poder extraer las características de manera más sencilla, para ello se utilizó el archivo adjunto a los datos de cada sujeto llamado “Reestimulos” (Ver sección 3.2.1.5), el cual es utilizado como plantilla para obtener los datos de cada movimiento con mayor fiabilidad, La Figura 3.10 muestra la gráfica de la sEMG del canal1 con todos los movimientos del sujeto 1 siguiendo el protocolo descrito en la sección 3.2.1.6, la gráfica del archivo de “Reestimulos” de ese mismo sujeto, y la gráfica de la señal ya concatenada.



(a)



(b)



(c)

Figura 3.10 a) Señal EMG de 10 movimientos del canal 1 del sujeto 1, b) Reetiquetado de la señal utilizando el algoritmo de (Kuzborskij et al., 2012), c) Señal EMG ya concatenada.

3.2.2.2 Segmentación de ventanas seleccionada

(Englehart & Hudgins, 2003) demostraron que reducir el tamaño de la segmentación de ventana a 128 ms (a una Frecuencia de muestreo de 1000 Hz) o incluso hasta los 32ms no tiene un decremento considerable en la precisión de la clasificación, aunque en casos de procesamiento en tiempo real debe considerarse también la velocidad a la que se procesaran los datos. En este proyecto optamos por utilizar la técnica de las ventanas traslapadas para obtener las ventanas de tiempo a analizar, se eligió esta técnica debido a que incrementar la ventana en segmentos pequeños produce una mayor densidad de datos pero también puede mejorar la respuesta en tiempo y precisión. Se

realizara la clasificación con dos tamaños de ventana distintos, uno de 200 ms con un traslape de 100 ms, y otro de 150 ms con un traslape de 25 ms, ya que (*Lauren, y otros 2011*) demostraron que el tamaño óptimo de ventana esta entre 150 y 250 ms para mantener un equilibrio entre el error en la clasificación y el tiempo de respuesta de un sistema en tiempo real, además, ambos están por debajo de 300 ms en orden de satisfacer las restricciones para su implementación en tiempo real.

3.2.2.3 Selección de grupos de características

Debido a las ventajas de las características extraídas en el tiempo, para este proyecto se decidió utilizar 4 grupos de características TD que han mostrado buenos rendimientos en la literatura. El grupo TD1 (*Y.-C. Du et al., 2010*) está compuesto por la integral de la señal sEMG (IEMG), la varianza (VAR), la amplitud de Willison (WAMP), la longitud de onda (WL), el cambio de signo de pendiente (SSC) y cruces por cero (ZC). El grupo TD2 (*Huang et al., 2012*) está compuesto por el valor absoluto medio (MAV), SSC, WL, VAR, WAMP, ZC y los cuatro coeficientes del modelo de autoregresión (AR), estos dos primeros grupos fueron seleccionados debido a los buenos rendimientos obtenidos por (*Wei et al., 2019*) para clasificar las bases de datos DB2 y DB3, el tercer grupo TD-PSD1, el cual consiste en dos características derivadas de los momentos del espectro de potencia en el tiempo propuestos por (*Pancholi et al., 2021*), la primer característica es el número de picos multiplicada por la señal de potencia (MPP) y la segunda característica son los cruces por cero multiplicadas por la señal de potencia (MZP), y el cuarto grupo TD-PSD2 tomado de (*Khushaba et al., 2012*) las cuales por primera vez son utilizadas para el entrenamiento de una CNN. Las características TD-PSD2 se detallaron en la sección 2.3.2.4. Para ver las fórmulas de cada una de las características de todos los grupos ir al Apéndice B.

La Tabla 3.1 muestra los grupos como están compuestos los cuatro grupos de características utilizados en esta metodología.

Tabla 3.1 Grupos de características TD utilizados en este proceso experimental.

TD1	TD2	TD-PSD1	TD-PSD2
IEMG	MAV	MMP	f_1
VAR	SSC	MZP	f_2
WAMP	WL		f_3
WL	VAR		f_4
SSC	WAMP		f_5
ZC	ZC		
AR (4)			

3.2.2.4 Formación de imágenes

Para este proyecto se decidió utilizar dos de los clasificadores que han mostrado el mejor rendimiento para la clasificación de patrones de señales sEMG, las redes ANN y CNN, para el segundo caso la red requiere -como se mencionó en el capítulo anterior- que las entradas sean imágenes. Inspirados en los buenos resultados de (Hu et al., 2018a). La formación de la imagen inicial se realiza como se muestra en la Figura 3.11, donde se muestra un ejemplo de la formación de una matriz derivada de la extracción de características TD1 de una ventana en el tiempo tomada de las señales sEMG.

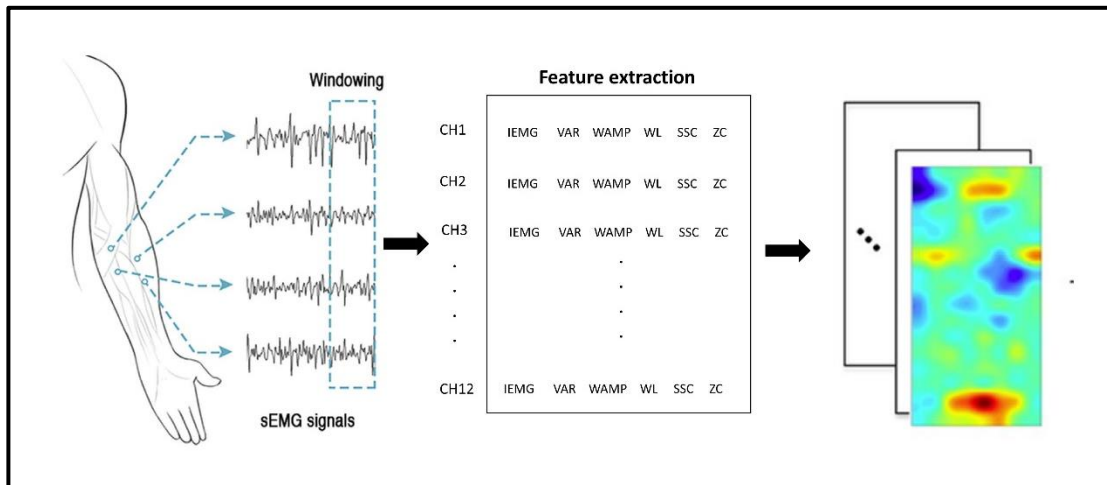


Figura 3.11 Formación de imagen derivado de la extracción de características TD1.

Para la evaluación de nuestros resultados se decidió utilizar 4 diferentes métodos de representación de imágenes, derivadas de la extracción de los cuatro grupos de características descritos en la sección previa, cada una de las imágenes se describe a continuación:

- **Feature Image** es obtenida directamente de la extracción de características de cada ventana, con un tamaño de $12 \times W$, donde 12 es el alto de la imagen (canales de adquisición) y W es el ancho de la imagen, igual al número de características extraídas.
- **MixChannel Image** es obtenida aplicando el algoritmo de reorganización a los canales de adquisición como lo propone (*W. Jiang & Yin, 2015*), donde se acomodan los canales de tal forma que cada uno es adyacente a todos los demás en una parte de la secuencia para buscar patrones de correlación, dejando una imagen de $72 \times W$ donde 72 es el alto de la imagen después de aplicar el algoritmo y W es el ancho de la imagen; igual al número de características extraídas, las cuales dependen del grupo de características utilizado.

- **MixFeature Image** es obtenida al aplicar el algoritmo de reorganización, pero esta vez a las características de la ventana, para buscar patrones de correlación esta vez entre características, dejando una imagen de un tamaño de $12 \times W$, donde 12 es el alto de la imagen (canales) y W es el ancho de la imagen; resultado de aplicar el algoritmo a las características, dejando un ancho de imagen diferente para cada grupo de características propuestos. Para el grupo TD-PSD1 este tipo de imagen no se implementó porque solo tiene dos características, y ya son adyacentes una de la otra.
- **Mix Image** es obtenida de aplicar el algoritmo de reorganización tanto en canales como en características, buscando obtener la mayor cantidad de información posible de todas las posibles correlaciones, dejando una imagen de $72 \times W$, donde 72 es la altura de la imagen después de aplicar el algoritmo a los canales, y W es el ancho de la imagen después de aplicar el algoritmo a las características, dejando un ancho de imagen diferente para cada uno de los grupos de características propuestos. Al igual que en el tipo de imagen anterior, para el grupo TD-PSD1 este tipo de imagen no fue implementada debido a que solo tiene 2 características y la imagen generada sería idéntica a la imagen "MixChannel Image".

La Figura 3.12 muestra una representación traspuesta de cada tipo de imagen utilizada para evaluar el rendimiento de la CNN.

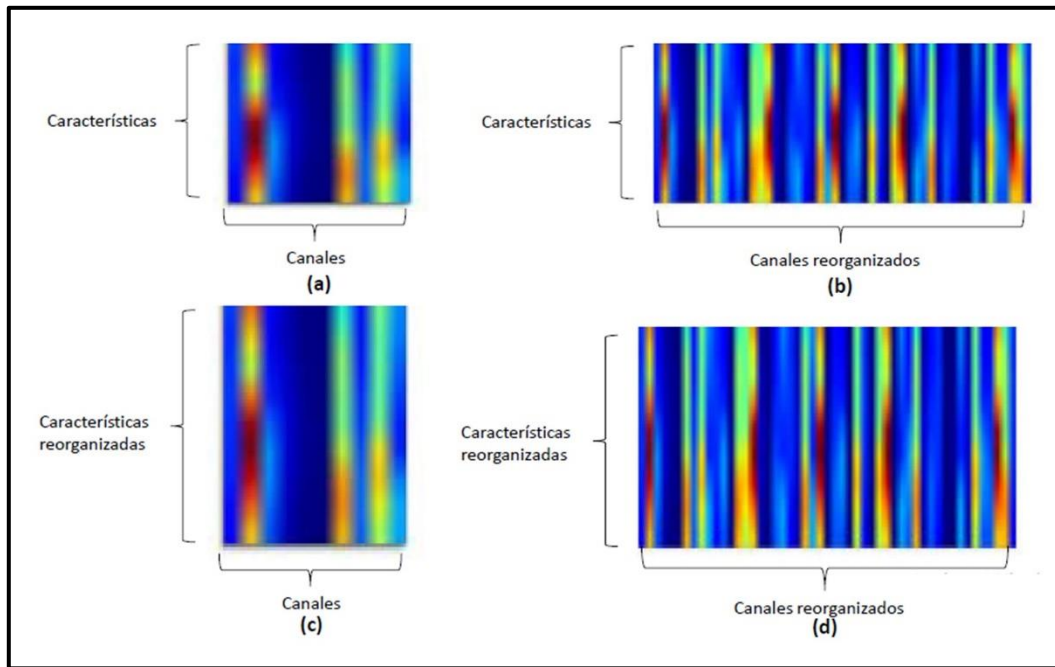


Figura 3.12 Formación de imágenes para el entrenamiento de una CNN donde: a) Son las características por los canales (FeatureImage), b) son las características por los canales reorganizados (MixChannellImage), c) son las características reorganizadas por el número de canales (MixFeatureImage), y d) son las características reorganizadas por los canales reorganizados (MixImage).

3.2.2.5 Clasificación

La última parte del proceso para reconocimiento de patrones es utilizar algún tipo de clasificador, en este caso, se utilizó una estructura ANN y una CNN para evaluar todos los grupos de características propuestos el diagrama de la Figura 3.13 muestra todos los esquemas evaluados en este estudio, utilizando dos bases de datos, dos tamaños de segmentación de ventana, cuatro grupos de características, dos tipos de clasificador y cuatro tipos de imágenes distintas para el caso de la estructura CNN.

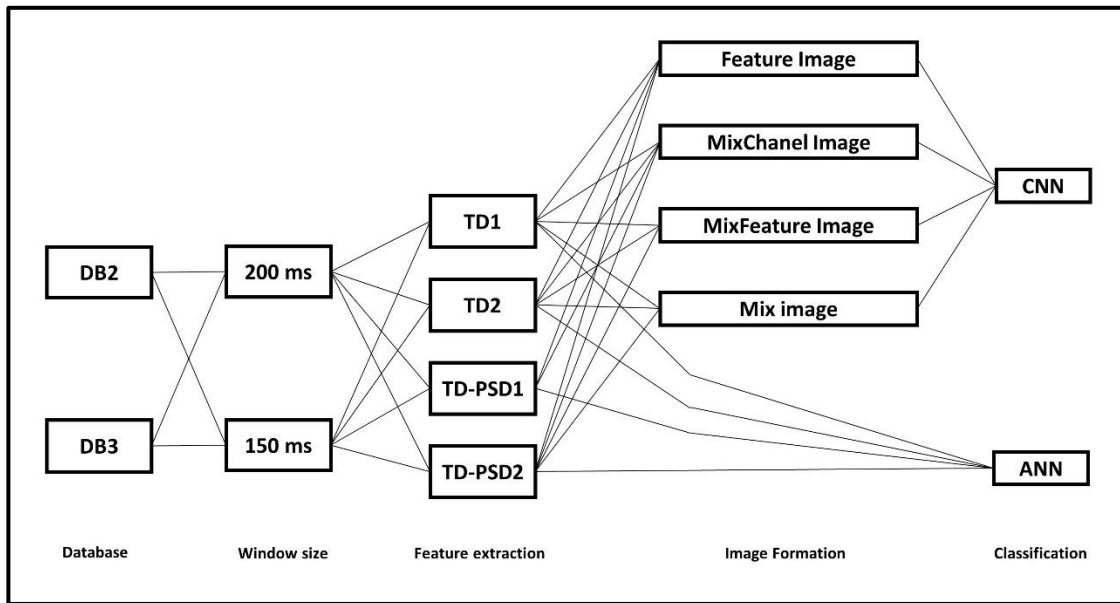


Figura 3.13 Combinaciones de todos los esquemas probados en este estudio.

3.2.2.5.1 Clasificador ANN

Para este proceso experimental se utilizaron las matrices resultantes de la extracción de características para todo los esquemas de la Figura 3.13 para aplicar un modelo ANN con una estructura como la de la Figura 3.14, donde las entradas son las características TD1 de cada uno de los 12 canales extraídas de las muestra de cada movimiento, por ejemplo, para las 6 características TD1 y considerando que son 12 canales de adquisición, la red neuronal tendrá un total de 72 entradas, y una salida por cada movimiento a clasificar, con una sola capa oculta con función de activación TANSIG y una función de activación PURELIN en la capa de salida. Para el entrenamiento de la red se utilizó el gradiente descendiente estocástico sobre la función de coste del error cuadrático medio con una velocidad de aprendizaje de 0.01, mientras que del total de ventanas extraídas se utilizó el 75 % para el entrenamiento (set de entrenamiento), y el 25 % restante para la validación (set de test).

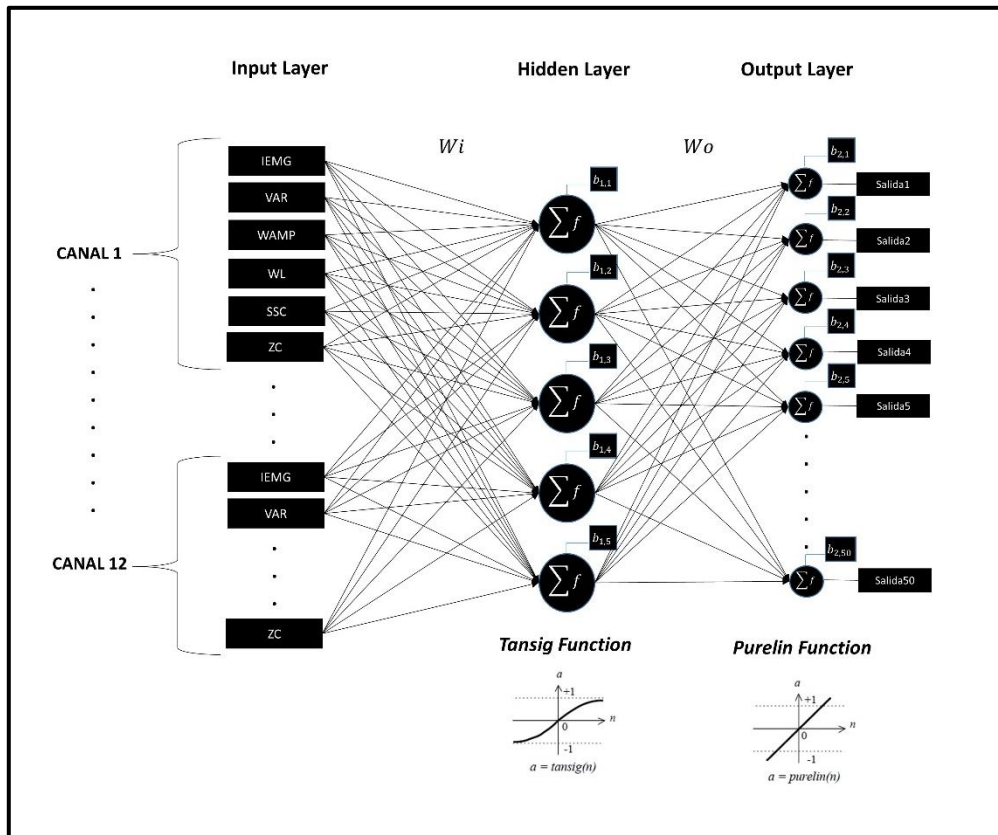


Figura 3.14 Estructura ANN empleada para la clasificación de 50 movimientos de la base de datos DB2 y DB3 para 12 canales de adquisición

El realizar el análisis con múltiples salidas nos permitió evaluar el rendimiento para cada movimiento utilizando la ecuación 26, donde las clasificaciones correctas del movimiento “n” corresponden a las muestras que el modelo clasificó en el movimiento que corresponde, y el total de muestras del movimiento “n” son el total de ventanas de cada movimiento en particular. El rendimiento total se calculó con la ecuación 27, considerando todas las muestras bien clasificadas y el total de las muestras.

$$\%Rendimiento\ de\ movimiento = \left(\frac{\text{clasificaciones correctas del movimiento "n"}}{\text{Total de muestras del movimiento "n"}} \right) \times 100 \quad (26)$$

$$\%Rendimiento\ total = \left(\frac{Clasificaciones\ correctas\ totales}{Total\ de\ muestras} \right) \times 100 \quad (27)$$

Además, calcular el rendimiento por movimiento nos permitió realizar el análisis mostrado en la Figura 3.15, y determinar cuál es el efecto de quitar los movimientos que muestran menor rendimiento individual del número total de muestras y volver a entrenar la red, para evaluar dos cosas: determinar si el rendimiento general aumenta cuando se intentan clasificar una menor cantidad de movimientos, y si los movimientos que muestran el mejor rendimiento son los mismos para todos los sujetos. Este análisis nos permitirá plantear parte de la metodología adecuada para cada sujeto en particular. Todo el procesamiento digital se realizó en el software MATLAB R2021a en un CPU con un procesador Intel Core i7-6700HQ 2.60 GHz.

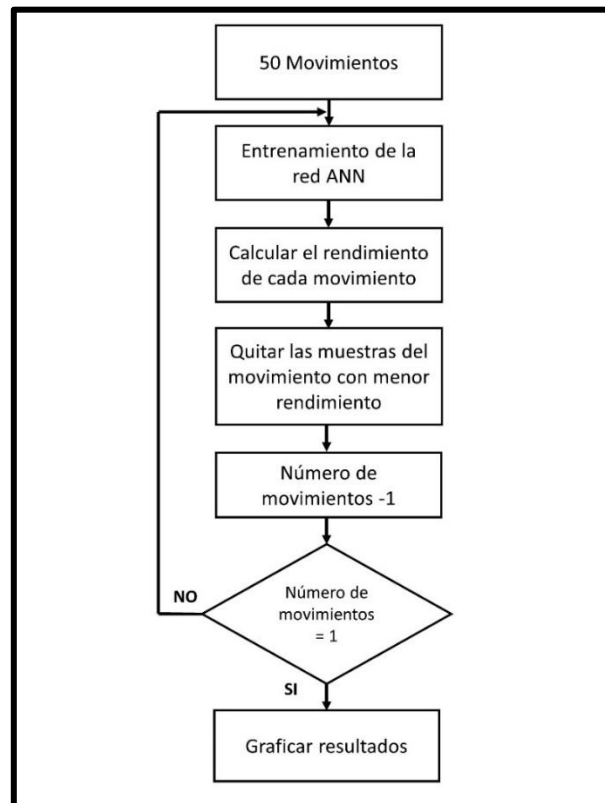


Figura 3.15 Algoritmo para calcular el rendimiento de clasificación al ir quitando los movimientos de menor rendimiento uno a uno.

En este trabajo se evaluó el rendimiento final del modelo generado por la red calculando la raíz del error cuadrático medio (*RMSE*), el error porcentual absoluto medio (*MAPE*), el coeficiente de determinación (R^2) y el coeficiente de correlación (R) (*Reyes-Téllez et al., 2020*). Para determinar que se tiene un buen modelo los errores deben acercarse a cero y los coeficientes de correlación y determinación a uno.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_{sim(i)} - x_{exp(i)})^2}{n}} \quad (28)$$

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{x_{exp(i)} - x_{sim(i)}}{x_{exp(i)}} \right|}{n} \times 100(\%) \quad (29)$$

$$R = \frac{\sum_{i=1}^n \{(x_{exp(i)} - \bar{x}_{exp})(x_{sim(i)} - \bar{x}_{sim})\}}{\sqrt{\sum_{i=1}^n (x_{exp(i)} - \bar{x}_{exp})^2} \sqrt{\sum_{i=1}^n (x_{sim(i)} - \bar{x}_{sim})^2}} \quad (30)$$

$$R^2 = \frac{\sum_{i=1}^n (x_{exp(i)} - x_{sim(i)})^2}{\sum_{i=1}^n (x_{exp(i)} - \bar{x}_{exp})^2} \quad (31)$$

3.2.2.5.2 Clasificador CNN

La arquitectura CNN utilizada (VerFigura 3.16) en este trabajo fue la red denominada GengNet propuesta por (*Geng et al., 2016*) y que ha dado buenos rendimientos para la clasificación de patrones utilizando señales mioeléctricas. La red está compuesta por ocho capas en total. Las primeras dos son capas

convolucionales con 64 filtros de 3 x 3, después de cada una de estas capas se aplicó un maxpooling de 2 x 2, las siguientes dos capas están localmente conectadas con 64 filtros de 1 x 1 cada una, para estas primeras 4 capas se aplicó Batch normalization (*Ioffe & Szegedy, 2015*) para reducir el cambio interno de covarianza entre capas, las subsecuentes tres capas son capas totalmente conectadas con 512, 512 y 128 neuronas respectivamente, y al final de la red, una salida de 50 neuronas determinadas por el número de gestos a clasificar de las bases de datos DB2 y DB3. Para las primeras siete capas de la red se utilizó una función de activación de unidad lineal rectificadora (ReLU), mientras que para la última capa se utilizó una función SoftMax. Para el entrenamiento, al igual que para la ANN, se utilizó el gradiente descendiente estocástico con una velocidad de aprendizaje de 0.01 y un momentum de 0.9. El tamaño de cada batch fue de 128 imágenes y el número de épocas por entrenamiento fue de 32. Estos hiperparámetros fueron seleccionados manualmente de acuerdo al ajuste manual en (*Goodfellow et al., 2016*).

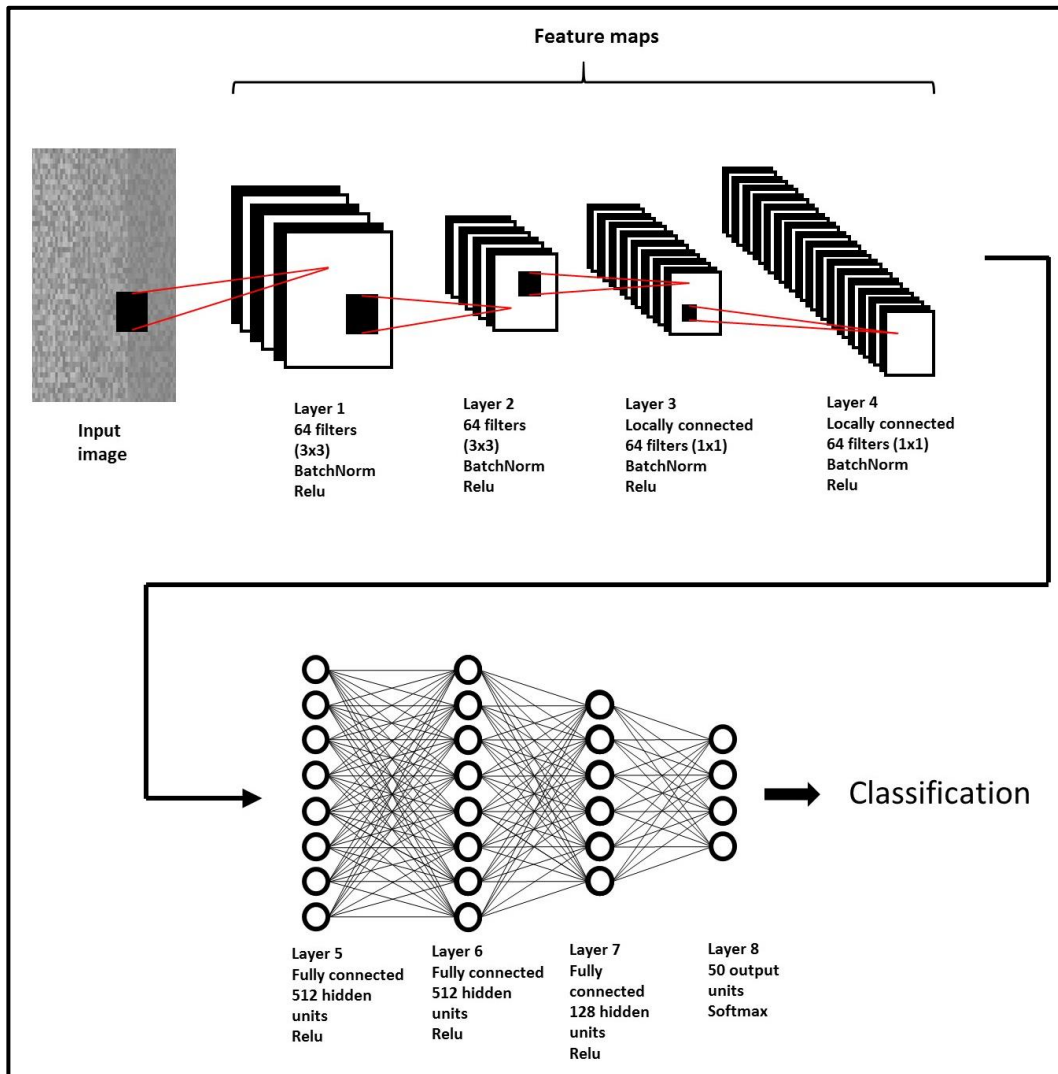


Figura 3.16 Arquitectura GengNet para la clasificación de 50 movimientos de las bases de datos DB2 y DB3.

Para la división de las muestras se siguió el mismo esquema que en (Atzori et al., 2016a; Hu et al., 2018a; Zhai et al., 2017), el cual consiste en utilizar 2/3 de las repeticiones de cada sujeto como el set de entrenamiento, y el 1/3 restante para el set de test. La precisión en la clasificación, al igual que con la red ANN, se calculó con base a la ecuación.

CAPÍTULO 4. RESULTADOS

En este capítulo se muestran los resultados obtenidos al aplicar todos los esquemas propuestos en este trabajo, donde se evaluaron todas las posibles combinaciones para las bases de datos NinaPro DB2 y DB3, que cuentan con información de 40 sujetos intactos y 11 sujetos amputados respectivamente, para ello se utilizaron dos segmentaciones de ventana distintos, cuatro grupos de características propuestos, y dos métodos de clasificación ANN y CNN, también se muestran los resultados obtenidos al quitar los movimientos con menor rendimiento uno a uno utilizando la red ANN.

4.1 Resultados implementando la estructura ANN

Se evaluó el rendimiento en la clasificación para cada sujeto de la base de datos Nina Pro DB2 y DB3 siguiendo el algoritmo de la Figura 3.9 sin considerar la formación de imágenes, una vez realizada la concatenación de la señal, se realizó la segmentación de ventanas con tamaño de 200 ms con un traslape de 100 ms, y se aplicó la extracción de los cuatro grupos de características de la Tabla 3.1 para evaluar todos los esquemas de la Figura 3.13.

4.1.1 Base de datos DB2 implementando ANN

Los resultados de la Figura 4.1 muestran el promedio de la precisión de la clasificación en porcentaje para los 40 sujetos de la base de datos DB2, donde el eje de las 'x' representa el número de movimientos, el cual va disminuyendo conforme se va quitando el de menor rendimiento en cada iteración del algoritmo general.

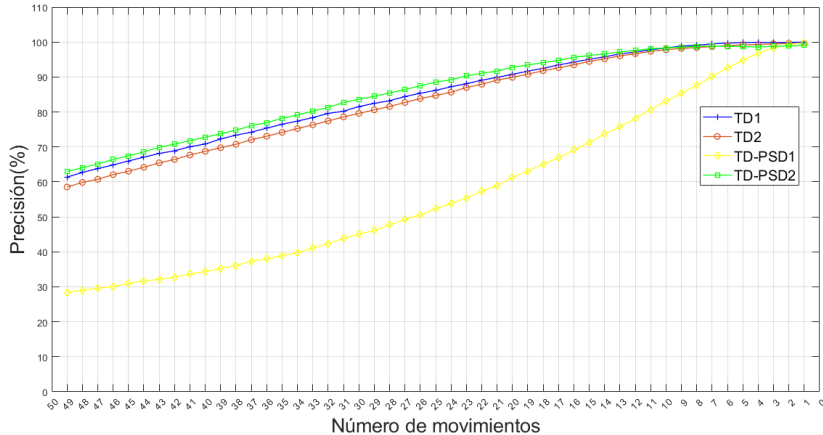
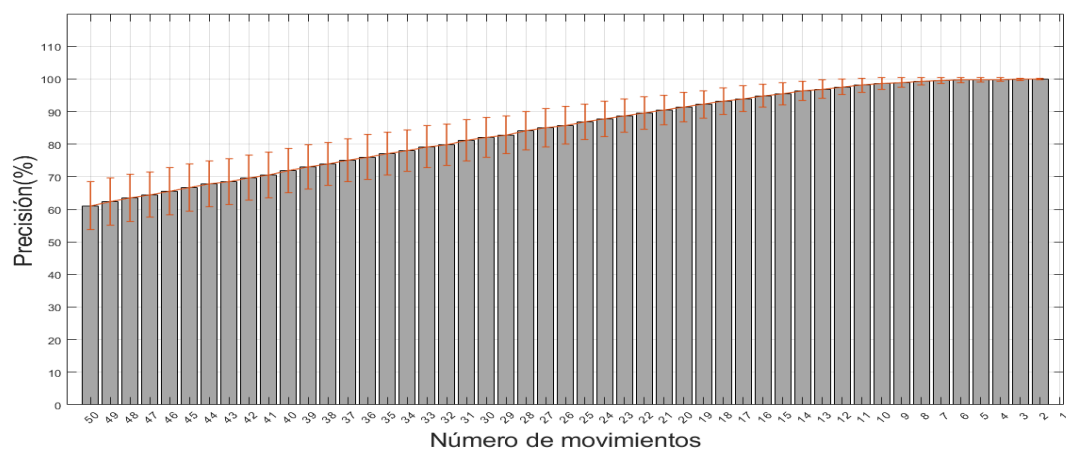


Figura 4.1 Promedio de rendimiento general para los 40 sujetos de la base de datos DB2 contra el número de movimientos clasificados para los 4 grupos de características propuestos.

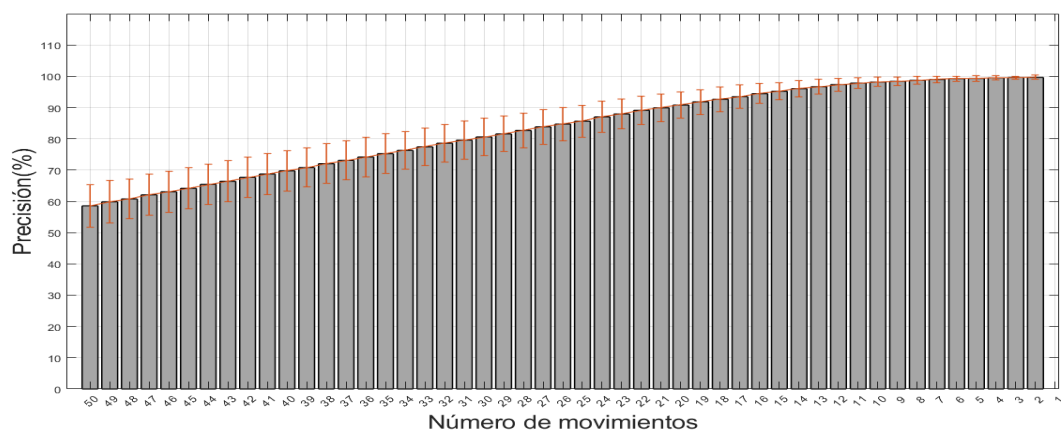
Cada línea representa a cada uno de los cuatro grupos de características utilizados, en la gráfica, se puede observar como el promedio de la precisión

va mejorando conforme se va depurando la matriz de muestras, lo cual ya se esperaba, logrando rendimientos superiores al 90 % después de haber quitado 30 de los 50 movimientos para las características TD1, TD2 y TD-PSD2, además, parece no haber una diferencia significativa al utilizar cualquiera de los 3 grupos de características, como lo demostró también (Hargrove , Englehart y Hudgins 2007), sin embargo, con las características TD-PSD1 el rendimiento promedio disminuye de manera considerable a pesar de que la tendencia es similar, es decir, el rendimiento promedio si aumenta conforme se van quitando los movimientos con menor rendimiento, pero no al mismo ritmo que con los otros 3 grupos de características.


La Figura 4.2 muestra los promedios de las precisiones para cada grupo de características por separado, con la desviación estándar de las precisiones para el grupo de 40 personas, donde además de la tendencia a incrementarse conforme se quitan los movimientos, también se puede ver que la desviación estándar va disminuyendo entre el conjunto de personas, de tal manera que cuando quedan 10 movimientos o menos, la variación es menor al 2 %, los rendimientos más altos para las primeras iteraciones donde aún se conservaban la mayor cantidad de movimientos se presentó al utilizar las características TD-PSD2, con un rendimiento promedio de 63.02% contemplando los 50 movimientos, por otro lado, el peor rendimiento se obtuvo con las características TD-PSD1, con un rendimiento promedio de 28.42%.




(a)



(b)




(c)




(d)

Figura 4.2 Promedio del rendimiento general con variación para los 40 sujetos de la base de datos DB2 contra el número de movimientos clasificados, para características a)TD1, b)TD2, c)TD-PSD1 y D)TD-PSD2.


A pesar de que es evidente que el error disminuye conforme se quitan los movimientos con menor rendimiento de la matriz de datos general, fue necesario para los objetivos de este trabajo, encontrar si los movimientos quitados para cada persona son distintos, para ello la Figura 4.3 muestra un código binario en blanco y negro, donde el color negro representa que el número de movimiento aún está presente en la matriz de datos, y el color blanco representa que el número de movimiento fue extraído de la matriz de datos por tener una baja precisión de clasificación, en la figura se muestra el código binario para la iteración 10, 20, 30 y 40 de los primeros 5 sujetos de la base de datos, haciendo énfasis que en la iteración 10 ya se han quitado los 10 movimientos con menor rendimiento, en la 20 se han quitado 20 movimientos y así sucesivamente.




(a)



(b)




(c)




(d)

Figura 4.3 Codificación binaria en blanco y negro para los movimientos que permanecen (color negro) y los extraídos (color blanco) de 5 sujetos de la base de datos DB2, en la iteración a) 10, b) 20, c) 30 y d) 40 del algoritmo de la Figura 3.15, utilizando las características TD-PSD2.

A cada iteración podemos observar que los códigos binarios para cada una de las 5 personas son distintos, lo que quiere decir que, en cada caso, los movimientos que a cada iteración dieron menor rendimiento no son los mismos para cada persona. También, de la Figura 4.3d, podemos observar que, de los cuatro grupos de movimientos de la base de datos, los movimientos que al final más permanecen son los del grupo B y D de los movimientos descritos en la base de datos, es decir, los correspondientes a movimientos básicos de dedos y de la muñeca, y a los patrones de fuerza, los movimientos del grupo C que corresponden a movimientos funcionales y de agarre han sido descartados en su mayoría lo que indica que son movimientos en general difíciles de clasificar. La Figura 4.4 muestra la codificación binaria para las 50 iteraciones de 2 sujetos de la base de datos, donde también se puede observar que poca similitud entre ambos, lo que reafirma el hecho de que los movimientos que se van retirando por bajo rendimiento en cada iteración, son distintos para cada persona.



(a)



(b)

Figura 4.4 Codificación binaria por colores para los movimientos que permanecen (color blanco) y los extraídos (color negro) de 2 sujetos de la base de datos DB2, en las 50 iteraciones del algoritmo de la Figura 3.15, utilizando características TD-PSD2.

En la Tabla 4.1, se puede observar el cálculo de los 4 parámetros estadísticos para los 20 mejores movimientos del sujeto 1 utilizando las características TD-PSD2, los parámetros se calcularon en la iteración 30 del algoritmo general de procesamiento, es decir, una vez que se quitaron los 30 movimientos con

menor precisión en la clasificación, y después se calcularon los mismos parámetros para la iteración 1, cuando están todos los movimientos presentes. Los resultados muestran que tanto el coeficiente de correlación como el coeficiente de determinación aumentan en la iteración 30 para todos los movimientos seleccionados, lo que es un indicativo de que una vez quitados los 30 movimientos con menor rendimiento los datos de salida tienen una mejor correlación con los datos deseados, y que, además, la calidad del modelo es mejor para replicar los resultados obtenidos. En cuanto al RMSE y el MAPE, en algunos movimientos es menor en la iteración 1 y en algunos es menor en la iteración 30, lo que es un indicativo que la desviación estándar del error en todos los puntos se mantiene a lo largo de las iteraciones, sin embargo, el MAPE siempre se mantiene por debajo de 10, por lo que según (Lewis, 1982) es un modelo altamente preciso.

Tabla 4.1 R , R^2 , $RMSE$ y $MAPE$ para los 20 mejores movimientos del sujeto 1 de la base de datos DB2, calculados en la iteración 1 y en la iteración 30 del algoritmo general de procesamiento

Numero de movimient	Coeficiente de correlación		Coeficiente de determinación		RMSE		MAPE	
	Iteración 1	Iteración 30	Iteración 1	Iteración 30	Iteración 1	Iteración 30	Iteración 1	Iteración 30
1	0,9330	0,9600	0,8602	0,9087	0,1130	0,1237	0,9838	2,1647
2	0,6714	0,8676	0,4436	0,7406	0,1036	0,1012	1,1490	0,9459
3	0,5437	0,8761	0,2954	0,7642	0,1241	0,1026	1,5323	0,9480
5	0,6128	0,8174	0,3759	0,6677	0,1124	0,1174	1,2202	1,5232
8	0,7325	0,8899	0,5342	0,7876	0,1095	0,1054	1,2686	1,3298
9	0,4238	0,8535	0,1774	0,7246	0,1216	0,1017	1,4452	1,1423
10	0,5481	0,8575	0,3006	0,7277	0,1161	0,1020	1,3448	1,1960
15	0,4323	0,7941	0,1834	0,6296	0,1120	0,1082	1,2656	1,1888
17	0,4549	0,7958	0,2031	0,6224	0,1094	0,1069	1,1760	1,1183
19	0,3765	0,8126	0,1384	0,6554	0,1363	0,1241	1,8220	1,5429
25	0,4314	0,7878	0,1817	0,6175	0,1451	0,1406	2,1275	2,1131
32	0,5260	0,8037	0,2765	0,6431	0,1356	0,1358	1,8658	2,0848
33	0,4758	0,8076	0,2242	0,6434	0,1413	0,1366	1,9927	1,9442
38	0,3496	0,7936	0,1192	0,6244	0,1235	0,1156	1,4951	1,2630
39	0,6782	0,8853	0,4604	0,7812	0,1149	0,1044	1,3360	1,2940

41	0,5446	0,8610	0,2976	0,7226	0,1123	0,1012	1,2691	1,1458
43	0,4862	0,8424	0,2411	0,6997	0,1008	0,0932	1,0093	0,8683
46	0,3800	0,8146	0,1401	0,6346	0,1099	0,1028	1,1904	0,9525
49	0,5584	0,8395	0,3098	0,6854	0,0937	0,0909	0,8773	0,7201
50	0,4882	0,8414	0,2326	0,6953	0,1062	0,0960	1,0979	0,9867

4.1.2 Base de datos DB3 implementando ANN

De forma similar al análisis que se realizó con la base de datos DB2, la Figura 4.5 muestra los rendimientos promedio de los 11 sujetos de la base de datos DB3 para los 4 grupos de características, donde el eje de las 'x' representa el número de movimientos, al igual que con la base de datos DB2, se calculó el rendimiento promedio nuevamente cada vez que se quitaba el movimiento que dio el menor rendimiento en la iteración anterior. La grafica muestra que la tendencia es similar a la observada en las personas sin ninguna amputación, es decir, el rendimiento promedio aumenta conforme se quitan los movimientos con bajo rendimiento, sin embargo, también es claro que en lo general se obtuvo un menor rendimiento para todos los grupos de características, debido a que está demostrado que es más complicado clasificar señales obtenidas de personas amputadas que de personas sin ninguna amputación (A. H. Al-Timemy et al., 2013).


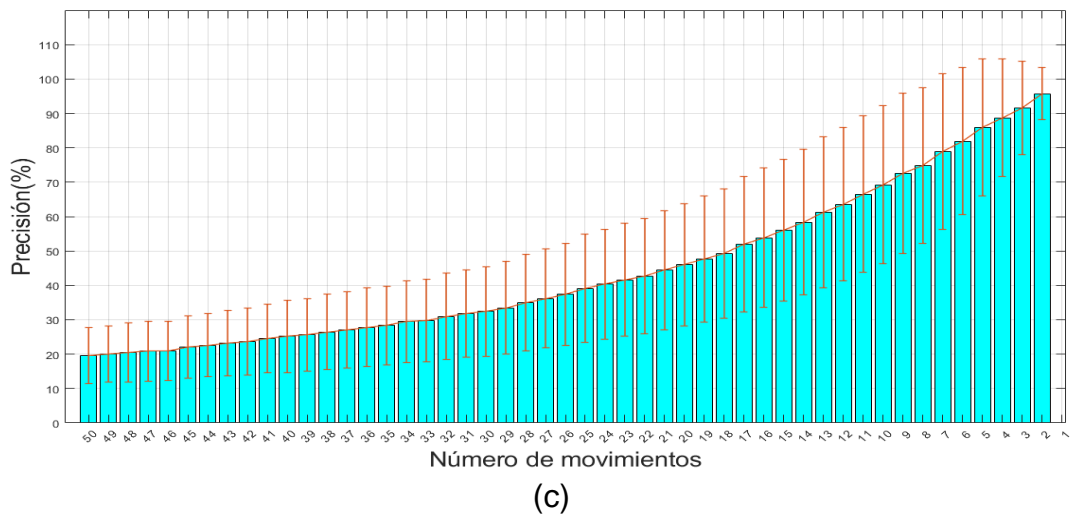
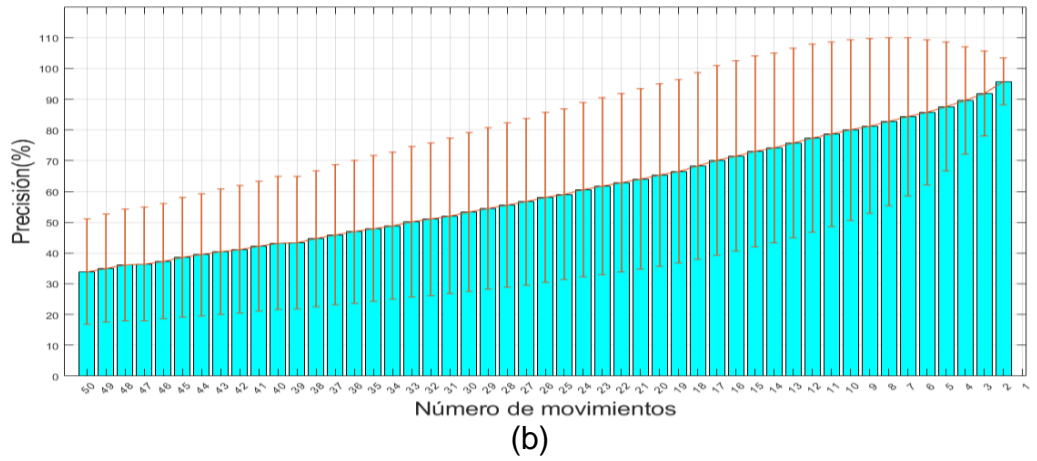




Figura 4.5 Promedio de rendimiento general para los 11 sujetos de la base de datos DB3 contra el número de movimientos clasificados para los 4 grupos de características propuestos.

A diferencia de los resultados obtenidos con las personas sin amputación, para este caso, los resultados muestran que para los 4 grupos de características el rendimiento está por encima del 90 % únicamente al quedarnos con 3 movimientos en la base de datos, aunque también es claro que las características que obtuvieron mayor rendimiento promedio a lo largo de todas las iteraciones fueron TD-PSD2 con un 34.05% considerando los 50 movimientos, y las que dieron el rendimiento promedio más bajo fueron TD-PSD1, con un 17.37% de igual forma para los 50 movimientos, lo cual es similar a lo encontrado en la base de datos DB2.

La Figura 4.6 muestra los promedios de las precisiones para cada grupo de características por separado, con la desviación estándar de las precisiones para el grupo de 11 personas, donde se puede observar que para todos los casos la desviación estándar se mantiene casi igual a pesar de ir quitando movimientos, lo que puede significar que hay uno o más sujetos en la base de datos que muestran rendimientos lejos de la media.






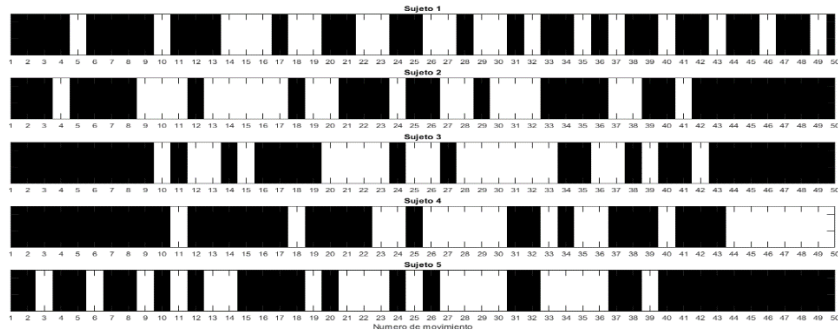
(d)

Figura 4.6 Promedio del rendimiento general con variación para los 40 sujetos de la base de datos DB3 contra el número de movimientos clasificados, para características a)TD1, b)TD2, c)TD-PSD1 y d)TD-PSD2.


Al igual que para la base de datos DB2, para este análisis se realizó una codificación binaria de 5 sujetos, la Figura 4.7 muestra los movimientos que permanecen (color negro) y los que fueron retirados (color blanco) por bajo rendimiento al momento de clasificarlos en la iteración 10, 20, 30 y 40. Al igual que con las personas amputadas, se puede observar que los movimientos que permanecen al final son distintos para cada persona, reafirmando nuestra hipótesis de que es necesario personalizar la clasificación de señales mioeléctricas para cada persona amputada para obtener un mejor rendimiento. Además, resulta particularmente interesante que los grupos de movimientos que al final más permanecen esta vez son los grupos B y C, es decir, los correspondientes a movimientos básicos y a movimientos funcionales y de agarre respectivamente, el grupo D correspondiente a movimientos de fuerza fueron descartados casi en su totalidad, lo cual puede deberse a que las personas amputadas muestran, en lo general, mayor debilidad muscular comparadas con las personas que no tienen ningún tipo de amputación.



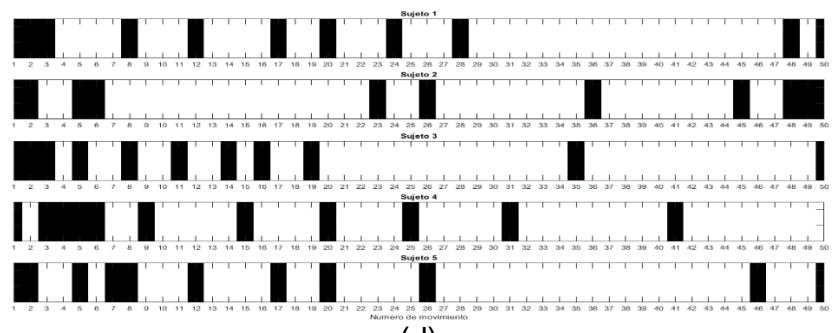
(a)



(b)




(c)




(d)

Figura 4.7 Codificación binaria en blanco y negro para los movimientos que permanecen (color negro) y los extraídos (color blanco) de 5 sujetos de la base de datos DB, en la iteración a) 10, b) 20, c) 30 y d) 40 del algoritmo de la Figura 3.15, utilizando las características TD-PSD2.

La Figura 4.8 muestra la codificación binaria para las 50 iteraciones de 2 sujetos de la base de datos DB3, donde al igual que con las personas sin amputación, también se puede observar que poca similitud entre ambos códigos binarios, lo que reafirma el hecho de que los movimientos que fueron retirados en cada iteración fueron distintos para cada persona.



(a)



(b)

Figura 4.8 Codificación binaria por colores para los movimientos que permanecen (color blanco) y los extraídos (color negro) de 2 sujetos de la base de datos DB3, en las 50 iteraciones del algoritmo de la Figura 3.15, utilizando características TD-PSD2.

En la Tabla 4.2, se puede observar el cálculo de los 4 parámetros estadísticos para los 20 mejores movimientos del sujeto 2 utilizando las características TD-

PSD2, al igual que para la base de datos DB2 los parámetros se calcularon en la iteración 30 del algoritmo general de procesamiento, y después se calcularon los mismos parámetros para la iteración 1, cuando están todos los movimientos presentes. Los resultados son similares a los mostrados en personas no amputadas, ya que muestran que tanto el coeficiente de correlación como el coeficiente de determinación aumentan en la iteración 30 para todos los movimientos seleccionados, lo que es un indicativo de que la calidad del modelo es mejor para replicar los resultados obtenidos. Por otro lado, el MAPE también se mantiene por debajo de 10 , por lo que según (Lewis, 1982) es un modelo altamente preciso.

Tabla 4.2 R , R^2 , $RMSE$ y $MAPE$ para los 20 mejores movimientos del sujeto 2 de la base de datos DB3, calculados en la iteración 1 y en la iteración 30 del algoritmo general de procesamiento.

Numero de movimient o	Coeficiente de correlación		Coeficiente de determinación		RMSE		MAPE	
	Iteración 1	Iteración 30	Iteración 1	Iteración 30	Iteración 1	Iteración 30	Iteración 1	Iteración 30
1	0,5768	0,8284	0,2918	0,6381	0,2413	0,2435	5,8810	6,4650
2	0,5985	0,7685	0,3504	0,5828	0,1091	0,1305	1,2064	1,7273
3	0,5865	0,7526	0,3381	0,5590	0,1185	0,1441	1,4267	1,7768
4	0,4194	0,7138	0,1761	0,5066	0,1117	0,1293	1,2460	1,6729
7	0,5915	0,7606	0,3482	0,5698	0,0944	0,1136	0,9291	1,2675
8	0,7099	0,7562	0,4968	0,5657	0,1068	0,1485	1,2086	2,2334
11	0,5399	0,7980	0,2784	0,6020	0,0804	0,0897	0,6206	0,6693
12	0,4076	0,7908	0,1623	0,6082	0,0986	0,0999	0,9463	0,8840
17	0,5875	0,8442	0,3379	0,7088	0,0951	0,0945	0,8803	0,8013
20	0,4971	0,7749	0,2466	0,5941	0,1026	0,1115	1,0425	1,2073
24	0,5169	0,6959	0,2643	0,4796	0,1095	0,1412	1,1898	1,8362
25	0,2722	0,8292	0,0677	0,6794	0,1454	0,1071	2,0748	1,1872
28	0,2377	0,7932	0,0455	0,6165	0,1333	0,1379	1,7125	1,7344
34	0,3359	0,6270	0,1165	0,3914	0,1406	0,1737	1,9679	2,8537
38	0,4979	0,7693	0,2437	0,5784	0,1301	0,1446	1,6941	2,0614
39	0,3666	0,7411	0,1323	0,5467	0,1394	0,1499	1,9165	2,2895
42	0,3921	0,6987	0,1513	0,4824	0,1342	0,1476	1,7876	2,1393
45	0,4223	0,7721	0,1792	0,5904	0,1320	0,1371	1,7473	1,8248
48	0,4039	0,8213	0,1581	0,6685	0,1337	0,1199	1,7415	1,3328
50	0,4854	0,7342	0,2365	0,5376	0,1256	0,1446	1,5949	2,0002

4.2 Resultados implementando la estructura CNN

Se evaluó el rendimiento de las bases de datos Nina Pro DB2 y DB3 siguiendo el procedimiento de la Figura 3.9, esta vez considerando la formación de los cuatro tipos de imagen descritos en la sección 3.2.2.4, esta vez se utilizaron dos tamaños de segmentación de ventana: 200 ms con un traslape de 100 ms, y 150 ms con un traslape de 25 ms, se analizaron los resultados para determinar cuál segmentación de ventana dio mejor resultado, cuál fue el grupo de características con mejor rendimiento, con qué tipo de imagen se obtuvo, y si fue consistente para todos los sujetos y poder concluir si se puede generalizar un esquema al momento de definir la metodología a proponer.

4.2.1 Base de datos DB2 implementando CNN

Los resultados obtenidos para los 40 sujetos de la base de datos DB2 utilizando los cuatro grupos de características propuestos y los cuatro tipos de imagen descritos pueden observarse en la Figura 4.9, para una segmentación de ventana de 200 ms con un traslape de 100 ms, las características TD-PSD2 mostraron el rendimiento más alto para todos los casos, además, el mayor rendimiento promedio para los 40 sujetos fue obtenido con el tipo de imagen "Mix Image" y fue de $87.56 \pm 4.46\%$, el segundo mejor rendimiento se obtuvo con las mismas características pero con el tipo de imagen "MixChannel Image" y fue de $87.19 \pm 4.53 \%$, solo 0.37% por debajo del mejor rendimiento, por otro lado, el rendimiento más bajo se obtuvo con el grupo de características TD-PSD1 y el tipo de imagen "Feature Image" y fue de $75.08 \pm 6.47\%$.


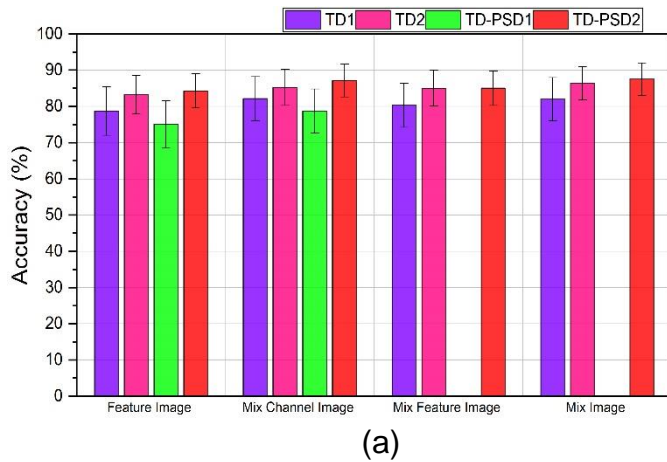



Figura 4.9 Precisión en la clasificación utilizando los cuatro tipos de imágenes propuestas para entrenar una red CNN para la base de datos DB2 con un tamaño de ventana de: a)200 ms y traslape de 100 ms; b)150 ms y traslape de 25 ms.


El rendimiento con la misma base de datos pero con una segmentación de ventana de 150 ms con un traslape de 25 ms mostraron, en general, un incremento en todos los rendimientos comparado con el primer tipo de segmentación, el promedio de rendimiento más alto también se obtuvo con las características TD-PSD2 y el tipo de imagen “Mix Image” y fue de $97.61 \pm 1.55\%$, además, el segundo mejor rendimiento fue de $97.44 \pm 1.11\%$, y esta vez se obtuvo con las características TD2 y el mismo tipo de imagen, con solo 0.17% debajo del mejor rendimiento, por otro lado, el menor rendimiento fue de $87.60 \pm 5.52\%$ y se obtuvo con las características TD-PSD1 y el tipo de imagen “Feature Image”.

El grupo de características que ofreció el mejor rendimiento fue el TD-PSD2, y para la mayoría de los casos el tipo de imagen que dio mejores resultados fue “Mix Image”, no obstante, la diferencia obtenida respecto al tipo de imagen “MixChannel Image” es pequeña, es por eso que se decidió hacer una comparación directa entre los 40 sujetos de la base de datos utilizando las

características TD-PSD2, ambos tipos de imágenes, y los dos tamaños de ventana, los resultados pueden observarse en la Figura 4.10.



(a)



(b)

Figura 4.10 Precisión de la clasificación de los 40 sujetos de la base de datos DB2 utilizando las características TD-PSD2, los tipos de imagen MixChannel Image y Mix Image, con un tamaño de ventana de: a) 200 ms y un traslape de 100 ms; b) 150 ms y un traslape de 25 ms.

Los resultados mostraron que aunque hay una pequeña diferencia en el promedio de porcentaje para todos los sujetos, utilizando la segmentación de 200 ms el rendimiento para 30 de los 40 sujetos se incrementó cuando utilizamos “Mix Image” comparado con “Mix Channel Image”, mientras que para una segmentación de 150 ms, 34 de los 40 sujetos presentaron un mejor rendimiento utilizando “Mix Image”.

4.2.2 Base de datos DB3

El rendimiento promedio obtenido para la base de datos DB3 mostro un comportamiento similar al obtenido con la base de datos DB2 como se muestra en la Figura 4.11. Los resultados muestran que cuando se utiliza una segmentación de 200 ms con un traslape de 100 ms, la mayor precisión fue de $74.24 \pm 9.45\%$ y fue obtenida con las características TD-PSD2 con el tipo

de imagen “Mix Image”, mientras que el segundo mejor rendimiento se obtuvo con las mismas características, pero con el tipo de imagen “Mix Channel Image” con un $73.55 \pm 9.08\%$, solo 0.69% de diferencia uno con otro. El menor rendimiento fue obtenido, al igual que con la base de datos DB2, fue con las características TD-PSD1 y el tipo de imagen “Feature Image” y fue de 60.94 ± 9.44 .




Figura 4.11 Precisión en la clasificación utilizando los cuatro tipos de imágenes propuestas para entrenar una red CNN para la base de datos DB3 con un tamaño de ventana de: a) 200 ms y traslape de 100 ms; b) 150 ms y traslape de 25 ms.

Los resultados obtenidos para la misma base de datos con una segmentación de 150 ms con un traslape de 25 ms, como con la base de datos DB2, mostraron un incremento en el rendimiento para todos los casos, el mayor rendimiento se obtuvo de nueva cuenta con las características TD-PSD2 y con el tipo de imagen “Mix Image” con un $90.23 \pm 6.82\%$, el segundo mejor rendimiento fue obtenido con el mismo tipo de características pero con el tipo de imagen “MixChannel Image” y fue de $90.03 \pm 7.57\%$, solo 0.2% debajo del mayor, el menor rendimiento fue de 76.77 ± 9.07 y, como en el análisis previo, fue obtenido con las características TD-PSD1 con el tipo de imagen “Feature Image”.

La diferencia entre los mejores rendimientos, al igual que con la base de datos DB2, fue mínima, por esa razón decidimos comparar los rendimientos para cada sujeto individualmente utilizando únicamente los dos esquemas que dieron mejor resultado; las características TD-PSD2 con los tipos de imagen “Mix Image” y “MixChannel Image”, los resultados se muestran en la Figura 4.12.




Figura 4.12 Precisión de la clasificación de los 40 sujetos de la base de datos DB2 utilizando las características TD-PSD2, los tipos de imagen MixChannel Image y Mix Image, con un tamaño de ventana de: a)200 ms y un traslape de 100 ms; b) 150 ms y un traslape de 25 ms.

Los resultados muestran que, a pesar de la pequeña diferencia entre los promedios de porcentajes, utilizando la segmentación de 200 ms, el rendimiento se incrementó para nueve de los 11 sujetos cuando utilizamos el tipo de imagen “Mix Image”, mientras que, para la segmentación de 150 ms, fueron 7 de los 11 sujetos quienes presentaron un incremento en la precisión utilizando el mismo tipo de imagen.

La Tabla 4.3 muestra un resumen de los rendimientos más altos de clasificación obtenidos de cada base de datos para ambas segmentaciones, indicando también el tipo de imagen y el grupo de características con que fueron obtenidos.

Tabla 4.3 Precisión de clasificación más alta lograda para las bases de datos DB2 y DB3.

Base de datos	Segmentación	Grupo de características	Tipo de imagen	Precisión promedio
DB2	200 ms	TD-PSD2	Mix Image	87.56 ± 4.46
	150 ms	TD-PSD2	Mix Image	97.61 ± 1.55
DB3	200 ms	TD-PSD2	Mix Image	74.24 ± 9.45
	150 ms	TD-PSD2	Mix Image	90.23 ± 6.82

4.2.3 Comparación de tiempos de procesamiento

Para este estudio se realizó el análisis del tiempo de procesamiento, el análisis incluye el tiempo que le toma a una muestra ser procesada desde la segmentación de la ventana, la extracción de características, y la aplicación del modelo CNN generado después del entrenamiento. Se tomaron cinco sujetos de cada base de datos para el análisis, se promedió el tiempo de procesamiento de todas las muestras para cada uno de los esquemas planteados. El análisis fue realizado en el software MATLAB R2021a en un CPU con un procesador Intel Core i7-6700HQ 2.60 GHz. Los resultados mostrados en la Figura 4.13 son los tiempos de procesamiento relativos al tiempo obtenido con las características TD-PSD3 y el tipo de imagen “Mix Image” el cual fue de 12 ms, este esquema fue seleccionado como base debido a que fue el que mostro el mejor rendimiento para ambas bases de datos y ambos tipos de segmentación de ventana.




Figura 4.13 Tiempo de procesamiento para la clasificación de una muestra relativo al tiempo de procesamiento utilizando las características TD-PSD2 con el tipo de imagen "Mix Image".

El análisis muestra que el tiempo de procesamiento de cada uno de los esquemas es consistente con el número de características que tiene en cada caso, y también es proporcional al tamaño de las imágenes (Ver Tabla 4.4). Por ejemplo, el grupo TD-PSD1 solo tiene dos características, y es el esquema que en promedio toma menos tiempo procesar las muestras para los tipos de imagen "Feature Image" y "MixChannel Image" con un 36.44% y 56.07% del tiempo que fue obtenido por el mejor rendimiento respectivamente, considerando que para los otros dos tipos de imágenes no se implementó. Por otro lado, el grupo TD2 tiene el mayor número de características con 10, y es el grupo que en promedio le tomó más tiempo de procesamiento para todos los casos de imágenes, además, con este tipo de características y el tipo de imagen "Mix Image" se encontró la diferencia más significativa con un 313.76% más de tiempo de procesamiento en comparación con el esquema con mejor rendimiento. Es importante mencionar, que todos los tiempos calculados están por debajo de los 200 ms, el mínimo tiempo de respuesta para satisfacer las restricciones de la interacción máquina-humano (Milosevic et al., 2017).

Tabla 4.4 Tamaño de cada imagen relativo al tamaño de la imagen con el mejor rendimiento mostrado (dado en porcentaje).

Tipo de imagen	TD1	TD2	TDPSD1	TD-PSD2
Feature Image	9.0	15.1	3.0	7.5
MixChannel Image	54.5	90.9	18.1	45.5
MixFeature Image	27.2	75.7	-	16.6
Mix Image	163.6	454.5	-	100

Los resultados para la base de datos DB2 utilizando una segmentación de 200 ms mostraron que la precisión más alta obtenida fue solo 0.37% mayor que el segundo mejor, por otro lado, la diferencia entre ambos tiempos fue de 23.08%, requiriendo más procesamiento el primero. Para el caso de la misma base de datos pero con un tamaño de ventana de 150 ms, la diferencia en precisión del esquema con mejor rendimiento con características TD-PSD2 y del segundo mejor con las características TD2 fue de solo 0.17%, siendo mejor el primero, sin embargo, en esta ocasión la diferencia de tiempos fue más significativa, con el segundo esquema siendo 313.76% más tardado que el primero, con este análisis, la ventaja de utilizar características TD-PSD2 se acentúa, debido a que muestra un ligero incremento en el rendimiento de la clasificación y un ahorro muy significativo en el tiempo de procesamiento.

CAPITULO 5. DISCUSIÓN Y CONCLUSIONES

En este capítulo se presentan una discusión de los resultados expuestos en el capítulo anterior con trabajos similares en la literatura. Además, se describen las conclusiones generales del proyecto y se plantea la metodología propuesta para la adquisición y clasificación de señales sEMG considerando todos los resultados obtenidos.

5.1 Discusión

Después de presentar los resultados en el capítulo anterior, es claro que las redes CNN tienen un rendimiento mayor que las redes ANN para todos los casos, nuestra discusión se centró en trabajos que han utilizado el mismo método de clasificación, para este trabajo, se utilizaron por primera vez las características TD-PSD2 para en entrenamiento de una red CNN, además, se propuso un nuevo tipo de imagen donde tanto los canales como las características fueron reorganizadas para buscar patrones adyacentes entre ellos.

La Tabla 5.1 compara los trabajos más recientes para la clasificación de patrones utilizando sEMG y la base de datos DB2 y DB3, mostrando los máximos rendimientos obtenidos, el tipo de método de clasificación utilizado, el tamaño de segmentación de ventana, y el número de movimientos a clasificar.

Tabla 5.1 Precisión de clasificación del esquema propuesto y de trabajos previos utilizando las bases de datos DB2 y DB3.

Autor	Base de datos	Movimientos	Tamaño de ventana	Clasificador	Precisión en %
(Atzori et al., 2016)	Nina Pro DB2	49	150ms	Random Forest	75.27
	Nina Pro DB3			SVM	46.27
(Zhai et al., 2017)	Nina Pro DB2	50	200ms	CNN	78.71
	Nina Pro DB3*	50			73.31
(Hu et al., 2018)	Nina Pro DB2	50	200ms	CNN-RNN	82.20
(Wei et al., 2019)	Nina Pro DB2	50	150ms	MV-CNN	82.70
			200ms		83.70
			200ms		64.30
(Pancholi et al., 2021)	Nina Pro DB2	49	150ms	DLPR	89.45
	Nina Pro DB3				81.67
Este trabajo	Nina Pro DB2	50	150ms	CNN	97.61
			200ms		87.56
	150ms		90.23		
	200ms		74.24		
	Nina Pro DB3				

La comparación muestra que la clasificación de la base de datos DB3 es más complicada, lo cual ya se esperaba, debido a que la estructura muscular de las extremidades de una persona amputada es diferente que el de una persona intacta (A. H. Al-Timemy et al., 2013). Desde (Atzori et al., 2016), quienes obtuvieron un 75.27% y un 46.27% de precisión para las bases de datos DB2 y DB3 respectivamente, y hasta el día de hoy, el rendimiento de estas bases de datos ha ido en incremento, siendo el clasificador de CNN y sus variantes quienes han dado mejores resultados. Los esquemas que dieron los rendimientos más altos en nuestro proceso experimental fueron al utilizar las características propuestas TD-PSD2 con el tipo de imagen propuesta “Mix Image”, por lo tanto, son los esquemas que comparamos con el resto de los trabajos en la Tabla 5.1. Para la base de datos DB2 con un tamaño de ventana de 150 ms, el rendimiento más alto fue de 97.61%, el cual es 8.16% más alto que el rendimiento logrado por (Pancholi et al., 2021) utilizando la misma segmentación de ventana. Por otro lado, el esquema propuesto por el mismo

(Pancholi et al., 2021) fue replicado en este trabajo en el esquema donde utilizamos las características TD-PSD1 y el tipo de imagen “MixChannel Image”, nuestro resultado fue 0.15% más alto, es decir prácticamente el mismo. Para la base de datos DB2 pero con una segmentación de 200 ms, el rendimiento más alto obtenido fue de 87.56% con un 3.86% más que el mejor rendimiento obtenido por (Wei et al., 2019) ,quienes utilizaron la misma segmentación de ventana y un clasificador CNN de múltiples vistas. Para la base de datos DB3 con una segmentación de 150 ms, el rendimiento más alto obtenido fue de 90.23%, lo que es 8.56% más alto que el reportado por (Pancholi et al., 2021), por otro lado, al igual que con la base de datos DB2, cuando comparamos esquemas similares nuestro rendimiento fue 0.05% mayor, por lo que podemos decir que los resultados fueron replicados satisfactoriamente. Por último, para la base de datos DB3 con una segmentación de ventana de 200 ms, el rendimiento más alto fue de 74.24%, que es 9.94% más alto que el obtenido por (Wei et al., 2019). Cabe señalar que (Zhai et al., 2017) reportaron un rendimiento de 73.31% para la base de datos DB3 utilizando una segmentación de 200 ms, sin embargo, ellos únicamente utilizaron 10 de los 50 movimientos disponibles, e incluso así, nuestro rendimiento fue 0.93% más alto utilizando los 50 movimientos.

5.2 Conclusiones

- Los resultados muestran que las redes neuronales convolucionales tienen mejor rendimiento tanto para los sujetos no amputados como para los sujetos amputados.
- Los resultados muestran que tanto las características propuestas TD-PSD2 como el tipo de imágenes “Mix Image” muestran los mejores rendimientos tanto para sujetos amputados como para los sujetos amputados al momento de entrenar una red CNN.

- La segmentación de ventana que dio mejor resultado fue la de 150 ms con un traslape de 25 ms, demostrando que se tiene un mejor rendimiento si se tiene una segmentación de ventana más pequeña, aunque también se debe considerar que le exige un menor tiempo de respuesta al sistema, por lo que se tiene que valorar con base al controlador que realizara el procesamiento final de los datos si vale la pena o no incrementar el rendimiento del sistema disminuyendo el tiempo de procesamiento.
- El rendimiento del modelo generado por las redes neuronales aumenta si se disminuye el número de movimientos a clasificar tanto para los sujetos amputados como para los sujetos no amputados, por lo que vale la pena valorar cuantos son los movimientos que realmente resulten de utilidad al momento de implementarlos en una prótesis real.
- Los movimientos que muestran mejor rendimiento en la clasificación no son los mismos para todos los sujetos, por lo que vale la pena analizar a cada sujeto de manera individual y definir cuáles son los movimientos que se clasifican con mayor precisión y utilizar solo cierta cantidad de ellos para entrenar un modelo que controle una prótesis electromecánica.

5.3 Metodología propuesta

Una vez analizados los resultados y sacando las conclusiones generales del proceso experimental, proponemos una metodología que se puede dividir en dos partes, primero la metodología para adquirir las señales y crear la base de datos que se puede observar en la Figura 5.1, la cual se definió con base a la literatura revisada y a la base de datos utilizada.




Figura 5.1 Metodología para la adquisición de señales sEMG para la clasificación de patrones de mano.

El número de electrodos se sugiere con base al estudio realizado por (A. H. Al-Timemy et al., 2013) y el protocolo de adquisición con base a la base de datos de Nina Pro. La segunda parte de la metodología se centra en la clasificación de patrones a partir de tener la base de datos, y se definió con base a los resultados obtenidos durante todo el procedimiento experimental, en la Figura 5.2 se puede observar la secuencia de la metodología sugerida, que inicia con la concatenación de las muestras obtenidas en el proceso de la adquisición de señales, de tal forma que se tenga una base de datos bien definida en cuanto al número de muestras por movimiento, después, se propone una segmentación de ventana de 150 ms con un traslape de 25 ms, que fue la que nos dio los mejores resultados tanto para sujetos amputados como para sujetos no amputados, cabe señalar que la selección del tamaño de ventana debe realizarse también con base al controlador que se utilizara para su implementación final. Una vez obtenidas las ventanas se sugiere realizar la extracción de características del grupo TD-PSD2, que de igual forma, fueron las que mostraron mejores rendimientos para ambos tipos de sujetos.

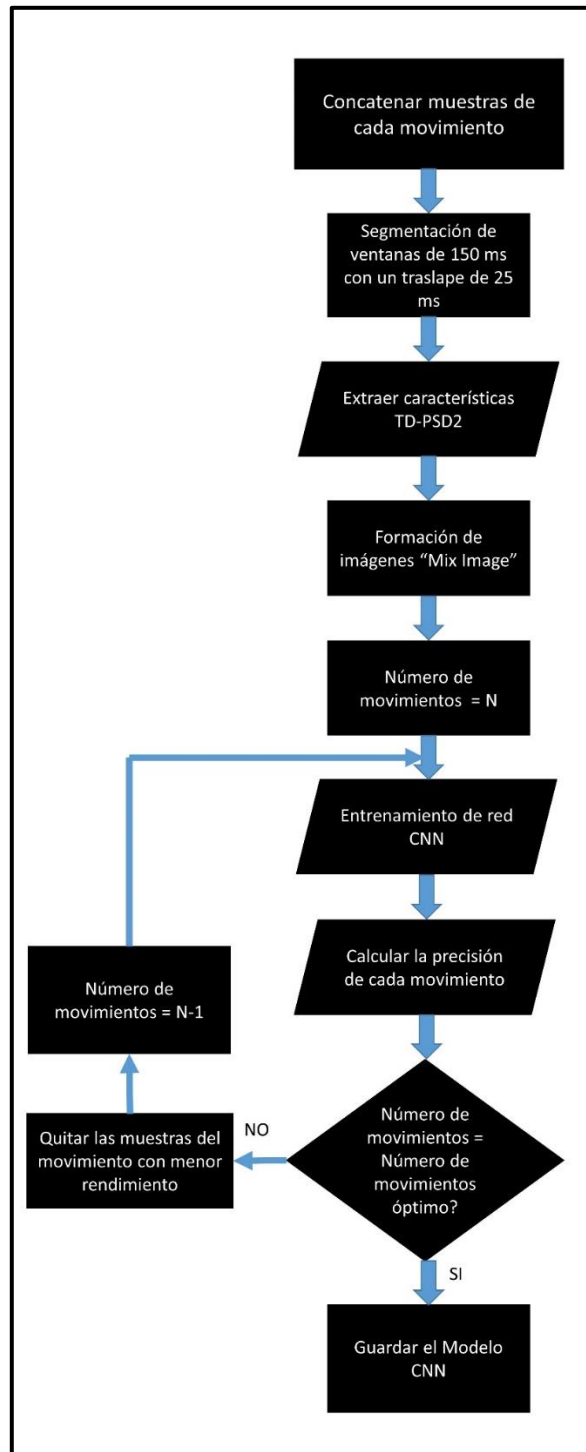


Figura 5.2 Metodología para la clasificación de patrones de mano utilizando redes neuronales convolucionales.

Para este trabajo se evaluó el rendimiento tanto para una estructura ANN como para una estructura CNN, y debido a que para todos los casos el rendimiento fue considerablemente mejor con la estructura CNN, el siguiente paso en la metodología propuesta es la formación de imágenes "Mix Image", que son imágenes propuestas en este trabajo y que consisten en aplicar el algoritmo de reorganización propuesto por (W. Jiang & Yin, 2015) tanto a los canales como a las características de la imagen formada, este tipo de imágenes dio los mejores rendimientos para todos los casos. Enseguida, se entrena la red neuronal CNN con todos los movimientos adquiridos, se calcula la precisión de cada movimiento y se quitan las muestras del movimiento que obtenga el menor rendimiento, de tal forma que el modelo generado vaya incrementando la precisión total y nos quedemos con la cantidad de movimientos suficiente para la aplicación final.

Es importante mencionar, que el número de movimientos a clasificar y la precisión considerada como aceptable, depende de la aplicación para la que esté dirigida la clasificación del modelo, para el caso del control de una prótesis electromecánica, se pueden utilizar estrategias que nos permitan minimizar el error a cero, realizando una moda de N cantidad de ventanas analizadas, a lo que se le conoce como "Majority voting", esto disminuirá el tiempo de respuesta del sistema pero evitará que la prótesis tenga sobresaltos derivados de clasificaciones mal realizadas.

CAPITULO 6. APENDICES

Apéndice A. Información general de los sujetos de prueba de la base de datos NINA PRO DB2 y DB3

Información general de los 40 sujetos de la base de datos NINA PRO DB2

Sujeto	Mano	Lateralidad	Genero	Edad	Altura (cm)	Peso (Kg)
1	Intacto	Diestro	Masculino	29	187	75
2	Intacto	Diestro	Masculino	29	183	75
3	Intacto	Diestro	Masculino	31	174	69
4	Intacto	Zurdo	Femenino	30	154	50
5	Intacto	Diestro	Masculino	25	175	70
6	Intacto	Diestro	Masculino	35	172	79
7	Intacto	Diestro	Masculino	27	187	92
8	Intacto	Diestro	Masculino	45	173	73
9	Intacto	Diestro	Masculino	23	172	63
10	Intacto	Diestro	Masculino	34	173	84
11	Intacto	Diestro	Femenino	32	150	54
12	Intacto	Diestro	Masculino	29	184	90
13	Intacto	Zurdo	Masculino	30	182	70
14	Intacto	Diestro	Femenino	30	173	59
15	Intacto	Diestro	Masculino	30	169	58
16	Intacto	Diestro	Masculino	34	173	76
17	Intacto	Diestro	Masculino	29	175	70
18	Intacto	Diestro	Femenino	30	169	90
19	Intacto	Diestro	Femenino	31	158	52
20	Intacto	Diestro	Femenino	26	155	52
21	Intacto	Diestro	Masculino	32	170	75

22	Intacto	Zurdo	Femenino	28	162	54
23	Intacto	Diestro	Masculino	25	170	66
24	Intacto	Diestro	Masculino	28	170	73
25	Intacto	Zurdo	Masculino	31	168	70
26	Intacto	Zurdo	Masculino	30	186	90
27	Intacto	Diestro	Masculino	29	170	65
28	Intacto	Diestro	Femenino	29	160	61
29	Intacto	Diestro	Masculino	27	171	64
30	Intacto	Diestro	Masculino	30	173	68
31	Intacto	Diestro	Masculino	29	185	98
32	Intacto	Diestro	Masculino	28	173	72
33	Intacto	Diestro	Masculino	25	183	71
34	Intacto	Diestro	Masculino	31	192	78
35	Intacto	Diestro	Femenino	24	170	52
36	Intacto	Diestro	Femenino	27	155	44
37	Intacto	Diestro	Masculino	34	190	105
38	Intacto	Diestro	Femenino	30	163	62
39	Intacto	Diestro	Masculino	31	183	96
40	Intacto	Diestro	Masculino	31	173	65

Información general de los 11 sujetos de la base de datos NINA PRO DB3

Sujeto	Mano amputada	Lateralidad	Edad	Altura (cm)	Peso (Kg)	Antebrazo restante (%)	Años desde la amputación	Causa de la amputación	Intensidad de sensación de extremidad fantasma	DASH Score	Uso de prótesis cosmética (años)	Uso de prótesis cinética (años)	Uso de prótesis mioeléctrica (años)
1	Derecha	Diestro	32	172	86	50	13	Accidente	2	1,67	0	0	13
2	Izquierda	Diestro	35	183	81	70	6	Accidente	5	15,18	6	0	0
3	Derecha	Diestro	50	178	82	30	5	Accidente	2	22,5	0	8	8
4	Derecha	Diestro	34	166	68	40	1	Accidente	1	86,67	0	0	0
5	Izquierda	Zurdo	67	175	75	90	1	Accidente	2	11,67	0	0,4	0
6	Izquierda	Diestro	32	172	66	40	13	Accidente	4	37,5	0	12	0
7	Derecha	Diestro	35	185	75	0	7	Accidente	0	31,67	0	0	6
8	Derecha	Diestro	33	175	80	50	5	Accidente	2	33,33	0	0	4
9	Derecha	Diestro	44	180	95	90	14	Accidente	5	3,33	0	0	14
10	Derecha	Diestro	59	177	86	50	2	Accidente	5	11,67	0	1,66	0
11	Derecha	Diestro	45	183	75	90	5	Cáncer	4	12,5	0	5	5

6.1 Apéndice B. Fórmulas de las características extraídas a las señales a las señales EMG

Fórmulas de las características extraídas a cada ventana (muestras) de las señales mioeléctricas

Característica	Ecuación Matemática
Valor absoluto de la media	$MAV_k = \frac{1}{N} \sum_{n=1}^N x_n $
Valor absoluto de la pendiente de la media	$MAVSLP_k = MAV_{k+1} - MAV_k$
Amplitud de Willison	$WAMP_k = \sum_{n=2}^{N-1} f(x_n - x_{n-1})$ $f(x) = \begin{cases} 1, & \text{if } x \geq \epsilon \\ 0, & \text{de otro modo} \end{cases}$
Varianza	$VAR_k = \frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^2$
Cruces por cero	$ZC_k = \sum_{n=1}^N f[(x_n > 0 \text{ and } x_{n+1} < 0) \text{ or } (x_n < 0 \text{ and } x_{n+1} > 0) \text{ and } x_n - x_{n-1} \geq \epsilon]$ $f(x) = \begin{cases} 1, & \text{if } x \text{ es True} \\ 0, & \text{if } x \text{ es False} \end{cases}$
Cambio del signo de la pendiente	$SSC_k = \sum_{n=2}^N f[(x_n > x_{i-1} \text{ and } x_n > x_{i+1}) \text{ or } (x_n < x_{i-1} \text{ and } x_n < x_{i+1})]$ <p style="text-align: center;">and</p> $(x_n - x_{n+1} \geq \epsilon \text{ or } x_n - x_{n-1} \geq \epsilon)$ $f(x) = \begin{cases} 1, & \text{if } x \text{ es True} \\ 0, & \text{if } x \text{ es False} \end{cases}$
Longitud de la forma de onda	$WL_k = \sum_{n=1}^N x_{n+1} - x_n $
Raíz cuadrática media	$RMS_k = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2}$
Modelo de auto regresión	$x_k = - \sum_{n=1}^N a_n x_{k-n} + e_k$

Frecuencia mediana	$F_{MD} = \frac{1}{2} \sum_{n=1}^M PSD_n$
Frecuencia media	$F_{MN} = \frac{\sum_{n=1}^M f_n PSD_n}{\sum_{n=1}^M PSD_n}$ $f_n = \frac{n * sampling_rate}{2 * M}$
Relación de frecuencias	$FR_k = \frac{ F(\cdot) _{k\ low\ freq.}}{ F(\cdot) _{k\ high\ freq.}}$
Frecuencia pico	$PKF = \max(PSD)$

Donde:

- k es el número de ventana o muestra de la señal mioeléctrica
- n es el número de dato de la ventana o muestra
- x_n es un valor del dato 'n' de una ventana o muestra de la señal mioeléctrica
- \bar{x} es la media de los datos de una ventana o muestra
- N es el número de total de datos de la ventana o muestra
- ε es un umbral definido para evitar los cruces por cero derivados del ruido de la señal
- a_n es el n-esimo coeficiente del modelo de auto regresión
- e_k es un término de error blanco de la muestra k
- PSD_n es la n-esima línea del espectro de densidad de potencia
- M es el número total de datos del espectro de densidad de potencia
- $|F(\cdot)|_{low\ freq.}$ son las frecuencias bajas de la transformada de fourier
- $|F(\cdot)|_{high\ freq.}$ son las frecuencias altas de la transformada de Fourier

BIBLIOGRAFÍA

- Abbaspour, S., Lindén, M., Gholamhosseini, H., Naber, A., & Ortiz-Catalan, M. (2020). Evaluation of surface EMG-based recognition algorithms for decoding hand movements. *Medical & Biological Engineering & Computing*, 58(1), 83-100. <https://doi.org/10.1007/s11517-019-02073-z>
- Academia Nacional de Medicina. (2016). *Los amputados y su rehabilitación. Un reto para el Estado* (Eduardo Vázquez Vela Sánchez). Intersistemas.
- Adewuyi, A. A., Hargrove, L. J., & Kuiken, T. A. (2016). Evaluating EMG Feature and Classifier Selection for Application to Partial-Hand Prosthesis Control. *Frontiers in Neurorobotics*, 10. <https://doi.org/10.3389/fnbot.2016.00015>
- Al-Timemy, A., Bugmann, G., & Escudero, J. (2018). Adaptive Windowing Framework for Surface Electromyogram-Based Pattern Recognition System for Transradial Amputees. *Sensors*, 18(8), 2402. <https://doi.org/10.3390/s18082402>
- Al-Timemy, A. H., Bugmann, G., Escudero, J., & Outram, N. (2013). Classification of Finger Movements for the Dexterous Hand Prosthesis Control With Surface Electromyography. *IEEE Journal of Biomedical and Health Informatics*, 17(3), 608-618. <https://doi.org/10.1109/JBHI.2013.2249590>
- Al-Timemy, A. H., Khushaba, R. N., & Escudero, J. (2016). Selecting the optimal movement subset with different pattern recognition based EMG control algorithms. *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 315-318. <https://doi.org/10.1109/EMBC.2016.7590703>

- Amma, C., Krings, T., Böer, J., & Schultz, T. (2015). Advancing Muscle-Computer Interfaces with High-Density Electromyography. *Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems*, 929-938. <https://doi.org/10.1145/2702123.2702501>
- Arica, S., Ara, R. K., & Özgünen, K. T. (2017). *On The Classification of Hand Movements with Electromyogram Signals Obtained From Arm Muscles for Controlling Hand Prosthesis*. 17, 8.
- Asghari Oskoei, M., & Hu, H. (2007). Myoelectric control systems—A survey. *Biomedical Signal Processing and Control*, 2(4), 275-294. <https://doi.org/10.1016/j.bspc.2007.07.009>
- Atzori, M., Cognolato, M., & Müller, H. (2016a). Deep Learning with Convolutional Neural Networks Applied to Electromyography Data: A Resource for the Classification of Movements for Prosthetic Hands. *Frontiers in Neurorobotics*, 10(9), 1-10. <https://doi.org/10.3389/fnbot.2016.00009>
- Atzori, M., Cognolato, M., & Müller, H. (2016b). Deep Learning with Convolutional Neural Networks Applied to Electromyography Data: A Resource for the Classification of Movements for Prosthetic Hands. *Frontiers in Neurorobotics*, 10. <https://doi.org/10.3389/fnbot.2016.00009>
- Atzori, M., Gijsberts, A., Castellini, C., Caputo, B., Hager, A.-G. M., Elsig, S., Giatsidis, G., Bassetto, F., & Müller, H. (2014). Electromyography data for non-invasive naturally-controlled robotic hand prostheses. *Scientific Data*, 1, 140053. <https://doi.org/10.1038/sdata.2014.53>
- Atzori, M., Gijsberts, A., Kuzborskij, I., Elsig, S., Mittaz Hager, A.-G., Deriaz, O., Castellini, C., Muller, H., & Caputo, B. (2015). Characterization of a

- Benchmark Database for Myoelectric Movement Classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 23(1), 73-83. <https://doi.org/10.1109/TNSRE.2014.2328495>
- Atzori, M., Gijsberts, A., Muller, H., & Caputo, B. (2014). Classification of hand movements in amputated subjects by sEMG and accelerometers. *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 3545-3549. <https://doi.org/10.1109/EMBC.2014.6944388>
- Basmaijian, J. V. (1967). *Muscles Alive. Their Functions Revealed by Electromyography* (2.^a ed.). Baltimore: Williams & Wilkins Co.
- Cavalcanti Garcia, M. A., & M. Vieira, T. M. (2010). Surface electromyography: Why, when and how to use it. *Rev Andal Med Deporte*, 4(1), 17-28.
- Chowdhury, R., Reaz, M., Ali, M., Bakar, A., Chellappan, K., & Chang, T. (2013). Surface Electromyography Signal Processing and Classification Techniques. *Sensors*, 13(9), 12431-12466. <https://doi.org/10.3390/s130912431>
- Cipriani, C., Antfolk, C., Controzzi, M., Lundborg, G., Rosen, B., Carrozza, M. C., & Sebelius, F. (2011). Online Myoelectric Control of a Dexterous Hand Prosthesis by Transradial Amputees. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 19(3), 260-270. <https://doi.org/10.1109/TNSRE.2011.2108667>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Coughlin, R. F., & Driscoll, F. F. (1993). *Amplificadores Operacionales y Circuitos Integrados Lineales*. PRENTICE-HALL HISPANOAMERICANA, S.A.

- da Silva, I. N., Hernane Spatti, D., Andrade Flauzino, R., Liboni, L. H. B., & dos Reis Alves, S. F. (2017). *Artificial Neural Networks*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-43162-8>
- De Luca, C. (2006). *Electromyography Encyclopedia of Medical Devices and Instrumentation* (John G. Webster). John Wiley Publisher.
- De Luca, C. J. (1997). The Use of Surface Electromyography in Biomechanics. *Journal of Applied Biomechanics*, 13(2), 135-163. <https://doi.org/10.1123/jab.13.2.135>
- DOF. (2011). *Decreto por el que se crea la Ley General para la Inclusión de las Personas con Discapacidad*. http://dof.gob.mx/nota_detalle.php?codigo=5191516&fecha=30/05/2011
- Du, Y., Jin, W., Wei, W., Hu, Y., & Geng, W. (2017). Surface EMG-Based Inter-Session Gesture Recognition Enhanced by Deep Domain Adaptation. *Sensors*, 17, 458. <https://doi.org/10.3390/s17030458>
- Du, Y.-C., Lin, C.-H., Shyu, L.-Y., & Chen, T. (2010). Portable hand motion classifier for multi-channel surface electromyography recognition using grey relational analysis. *Expert Systems with Applications*, 37(6), 4283-4291. <https://doi.org/10.1016/j.eswa.2009.11.072>
- Duchene, J., & Goubel, F. (1993). Surface electromyogram during voluntary contraction: Processing tools and relation to Physiological events. *Critical Reviews in Biomedical Engineering*, 4(21), 313-397.
- Englehart, K., & Hudgins, B. (2003). A robust, real-time control scheme for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, 50(7), 848-854. <https://doi.org/10.1109/TBME.2003.813539>

- Farina, D., Fosci, M., & Merletti, R. (2002). Motor unit recruitment strategies investigated by surface EMG variables. *Journal of Applied Physiology*, 92(1), 235-247. <https://doi.org/10.1152/jappl.2002.92.1.235>
- Fisher, R. A. (1936). THE USE OF MULTIPLE MEASUREMENTS IN TAXONOMIC PROBLEMS. *Annals of Eugenics*, 7(2), 179-188. <https://doi.org/10.1111/j.1469-1809.1936.tb02137.x>
- Freriks, B., & Hermens, H. (1999). *European Recommendations for Surface ElectroMyoGraphy: Results of the SENIAM Project*. Roessingh Research and Development.
- Gao, Z., Tang, R., Huang, Q., & He, J. (2021). A Multi-DoF Prosthetic Hand Finger Joint Controller for Wearable sEMG Sensors by Nonlinear Autoregressive Exogenous Model. *Sensors*, 21(8), 2576. <https://doi.org/10.3390/s21082576>
- Geng, W., Du, Y., Jin, W., Wei, W., Hu, Y., & Li, J. (2016). Gesture recognition by instantaneous surface EMG images. *Scientific Reports*, 6, 36571. <https://doi.org/10.1038/srep36571>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. <http://www.deeplearningbook.org>
- Guerrero Martínez, J. F. (2010). *Ingeniería Biomédica- Bioseñales*. Universidad de Valencia.
- Gurney, K. (2004). *Introduction to Neural Networks*. Taylor & Francis.
- Hallett, M., Berardelli, A., Delwaide, P., Freund, H.-J., Kimura, J., Lüking, C., Rothwell, J. C., Shahani, B. T., & Yanagisawa, N. (1994). Central EMG and tests of motor control. Report of an IFCN committee. *Electroencephalography*

and Clinical Neurophysiology, 90(6), 404-432. [https://doi.org/10.1016/0013-4694\(94\)90132-5](https://doi.org/10.1016/0013-4694(94)90132-5)

Hargrove, L., Englehart, K., & Hudgins, B. (2008). A training strategy to reduce classification degradation due to electrode displacements in pattern recognition based myoelectric control. *Biomedical Signal Processing and Control*, 3(2), 175-180. <https://doi.org/10.1016/j.bspc.2007.11.005>

Hargrove, L. J., Englehart, K., & Hudgins, B. (2007). A Comparison of Surface and Intramuscular Myoelectric Signal Classification. *IEEE Transactions on Biomedical Engineering*, 54(5), 847-853. <https://doi.org/10.1109/TBME.2006.889192>

Henneman, E., & Mendell, L. M. (1981). Functional Organization of Motoneuron Pool and its Inputs. En R. Terjung (Ed.), *Comprehensive Physiology* (1.^a ed., pp. 423-507). Wiley. <https://doi.org/10.1002/cphy.cp010211>

Hristev, R. M. (1998). *The ANN Book* (1.^a ed.).

Hu, Y., Wong, Y., Wei, W., Du, Y., Kankanhalli, M., & Geng, W. (2018a). A novel attention-based hybrid CNN-RNN architecture for sEMG-based gesture recognition. *PLOS ONE*, 13(10), 1-18. <https://doi.org/10.1371/journal.pone.0206049>

Hu, Y., Wong, Y., Wei, W., Du, Y., Kankanhalli, M., & Geng, W. (2018b). A novel attention-based hybrid CNN-RNN architecture for sEMG-based gesture recognition. *PLOS ONE*, 13(10), e0206049. <https://doi.org/10.1371/journal.pone.0206049>

Huang, H., Xie, H.-B., Guo, J.-Y., & Chen, H.-J. (2012). Ant colony optimization-based feature selection method for surface electromyography signals

- classification. *Computers in Biology and Medicine*, 42(1), 30-38.
<https://doi.org/10.1016/j.compbiomed.2011.10.004>
- Hudak, P. L., Amadio, P. C., Bombardier, C., Beaton, D., Cole, D., Davis, A., Hawker, G., Katz, J. N., Makela, M., Marx, R. G., Punnett, L., & Wright, J. (1996). Development of an upper extremity outcome measure: The DASH (disabilities of the arm, shoulder, and head). *American Journal of Industrial Medicine*, 29(6), 602-608. [https://doi.org/10.1002/\(SICI\)1097-0274\(199606\)29:6<602::AID-AJIM4>3.0.CO;2-L](https://doi.org/10.1002/(SICI)1097-0274(199606)29:6<602::AID-AJIM4>3.0.CO;2-L)
- Hudgins, B., Parker, P., & Scott, R. N. (1993). A new strategy for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, 40(1), 82-94. <https://doi.org/10.1109/10.204774>
- Ibn Ibrahimy, M., Ahsan, R., & Khalifa, O. O. (2013). Design and Optimization of Levenberg-Marquardt based Neural Network Classifier for EMG Signals to Identify Hand Motions. *Measurement Science Review*, 13(3), 142-151. <https://doi.org/10.2478/msr-2013-0023>
- INEGI. (2016). *La discapacidad en México, datos 2014*.
- Ioffe, S., & Szegedy, C. (2015). Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *Proceedings of the 32nd International Conference on International Conference on Machine Learning*, 37, 448-456. <https://doi.org/10.5555/3045118.3045167>
- Jiang, M. W., Wang, R. C., Wang, J. Z., & Jin, D. W. (2005). A Method of Recognizing Finger Motion Using Wavelet Transform of Surface EMG Signal. *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*, 2672-2674. <https://doi.org/10.1109/IEMBS.2005.1617020>

- Jiang, W., & Yin, Z. (2015). Human Activity Recognition Using Wearable Sensors by Deep Convolutional Neural Networks. *Proceedings of the 23rd ACM International Conference on Multimedia*, 1307-1310. <https://doi.org/10.1145/2733373.2806333>
- Kanitz, G. R., Antfolk, C., Cipriani, C., Sebelius, F., & Carrozza, M. C. (2011). Decoding of individuated finger movements using surface EMG and input optimization applying a genetic algorithm. *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 1608-1611. <https://doi.org/10.1109/IEMBS.2011.6090465>
- Khushaba, R. N., Lei Shi, & Kodagoda, S. (2012). Time-dependent spectral features for limb position invariant myoelectric pattern recognition. *2012 International Symposium on Communications and Information Technologies (ISCIT)*, 1015-1020. <https://doi.org/10.1109/ISCIT.2012.6380840>
- Konrad, P. (2005). *The ABC of EMG - A Practical Introduction to Kinesiological Electromyography* (1.0). Noraxon Inc.
- Kuzborskij, I., Gijsberts, A., & Caputo, B. (2012). On the challenge of classifying 52 hand movements from surface electromyography. *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 4931-4937. <https://doi.org/10.1109/EMBC.2012.6347099>
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1(4), 541-551. <https://doi.org/10.1162/neco.1989.1.4.541>

- Lewis, C. D. (1982). *Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting*. Butterworth Scientific.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115-133.
- Merletti, R., Botter, A., Troiano, A., Merlo, E., & Minetto, M. A. (2009). Technology and instrumentation for detection and conditioning of the surface electromyographic signal: State of the art. *Clinical Biomechanics*, 24(2), 122-134. <https://doi.org/10.1016/j.clinbiomech.2008.08.006>
- Merletti, R., & Parker, P. (Eds.). (2004). *Electromyography: Physiology, engineering, and noninvasive applications*. IEEE/John Wiley & Sons.
- Milosevic, B., Benatti, S., & Farella, E. (2017). Design challenges for wearable EMG applications. *Design, Automation & Test in Europe Conference & Exhibition (DATE), 2017*, 1432-1437. <https://doi.org/10.23919/DATE.2017.7927217>
- Naik, G. R., Kumar, D. K., & Arjunan, S. (2009). Use of sEMG in identification of low level muscle activities: Features based on ICA and fractal dimension. *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 364-367. <https://doi.org/10.1109/IEMBS.2009.5332489>
- Oskoei, M. A., & Hu, H. (2006). GA-based Feature Subset Selection for Myoelectric Classification. *2006 IEEE International Conference on Robotics and Biomimetics*, 1465-1470. <https://doi.org/10.1109/ROBIO.2006.340145>
- Oweis, R. J., Rihani, R., & Alkhawaja, A. (2014). ANN-based EMG classification for myoelectric control. *International Journal of Medical Engineering and Informatics*, 6(4), 365. <https://doi.org/10.1504/IJMEI.2014.065442>

- Pancholi, S., Joshi, A. M., & Joshi, D. (2021). *A Robust and Accurate Deep Learning based Pattern Recognition Framework for Upper Limb Prosthesis using sEMG* (arXiv:2106.02463). arXiv. <http://arxiv.org/abs/2106.02463>
- Park, K.-H., & Lee, S.-W. (2016). Movement intention decoding based on deep learning for multiuser myoelectric interfaces. *2016 4th International Winter Conference on Brain-Computer Interface (BCI)*, 1-2. <https://doi.org/10.1109/IWW-BCI.2016.7457459>
- Patel, G. K., Castellini, C., Hahne, J. M., Farina, D., & Dosen, S. (2018). A Classification Method for Myoelectric Control of Hand Prostheses Inspired by Muscle Coordination. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(9), 1745-1755. <https://doi.org/10.1109/TNSRE.2018.2861774>
- Phinyomark, A., Limsakul, C., & Phukpattaranont, P. (2009). *A Novel Feature Extraction for Robust EMG Pattern Recognition*. 1(1), 11.
- Phinyomark, A., Phukpattaranont, P., & Limsakul, C. (2012). Feature reduction and selection for EMG signal classification. *Expert Systems with Applications*, 39(8), 7420-7431. <https://doi.org/10.1016/j.eswa.2012.01.102>
- Rechy-Ramirez, E. J., & Hu, H. (s. f.). *Stages for developing control systems using EMG and EEG signals: A survey*. 33.
- Reyes-Téllez, E. D., Parrales, A., Ramírez-Ramos, G. E., Hernández, J. A., Urquiza, G., Heredia, M. I., & Sierra, F. Z. (2020). Analysis of transfer functions and normalizations in an ANN model that predicts the transport of energy in a parabolic trough solar collector. *DESALINATION AND WATER TREATMENT*, 200, 23-41. <https://doi.org/10.5004/dwt.2020.26063>

- Rim, B., Sung, N.-J., Min, S., & Hong, M. (2020). Deep Learning in Physiological Signal Data: A Survey. *Sensors*, 20(4), 969. <https://doi.org/10.3390/s20040969>
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386-408. <https://doi.org/10.1037/h0042519>
- Sebelius, F. C. P., Rosén, B. N., & Lundborg, G. N. (2005). Refined Myoelectric Control in Below-Elbow Amputees Using Artificial Neural Networks and a Data Glove. *The Journal of Hand Surgery*, 30(4), 780-789. <https://doi.org/10.1016/j.jhsa.2005.01.002>
- Sewak, M., Karim, M. R., & Pujari, P. (2018). *Practical Convolutional Neural Networks: Implement advanced deep learning models using Python*. Packt Publishing.
- Staudenmann, D., Roeleveld, K., Stegeman, D. F., & van Dieën, J. H. (2010). Methodological aspects of SEMG recordings for force estimation – A tutorial and review. *Journal of Electromyography and Kinesiology*, 20(3), 375-387. <https://doi.org/10.1016/j.jelekin.2009.08.005>
- Tenore, F., Ramos, A., Fahmy, A., Acharya, S., Etienne-Cummings, R., & Thakor, N. V. (2007). Towards the Control of Individual Fingers of a Prosthetic Hand Using Surface EMG Signals. *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 6145-6148. <https://doi.org/10.1109/IEMBS.2007.4353752>
- Tenore, F. V. G., Ramos, A., Fahmy, A., Acharya, S., Etienne-Cummings, R., & Thakor, N. V. (2009). Decoding of Individuated Finger Movements Using

- Surface Electromyography. *IEEE Transactions on Biomedical Engineering*, 56(5), 1427-1434. <https://doi.org/10.1109/TBME.2008.2005485>
- Wei, W., Dai, Q., Wong, Y., Hu, Y., Kankanhalli, M., & Geng, W. (2019a). Surface-Electromyography-Based Gesture Recognition by Multi-View Deep Learning. *IEEE Transactions on Biomedical Engineering*, 66(10), 2964-2973. <https://doi.org/10.1109/TBME.2019.2899222>
- Wei, W., Dai, Q., Wong, Y., Hu, Y., Kankanhalli, M., & Geng, W. (2019b). Surface-Electromyography-Based Gesture Recognition by Multi-View Deep Learning. *IEEE Transactions on Biomedical Engineering*, 66(10), 2964-2973. <https://doi.org/10.1109/TBME.2019.2899222>
- Yamanoi, Y., Ogiri, Y., & Kato, R. (2020). EMG-based posture classification using a convolutional neural network for a myoelectric hand. *Biomedical Signal Processing and Control*, 55, 101574. <https://doi.org/10.1016/j.bspc.2019.101574>
- Zahak, M. (2012). Signal Acquisition Using Surface EMG and Circuit Design Considerations for Robotic Prosthesis. En G. R. Naik (Ed.), *Computational Intelligence in Electromyography Analysis—A Perspective on Current Applications and Future Challenges*. InTech. <https://doi.org/10.5772/52556>
- Zecca, M., Micera, S., Carrozza, M. C., & Dario, P. (2002). Control of Multifunctional Prosthetic Hands by Processing the Electromyographic Signal. *Critical Reviews? In Biomedical Engineering*, 30(4-6), 459-485. <https://doi.org/10.1615/CritRevBiomedEng.v30.i456.80>
- Zhai, X., Jelfs, B., Chan, R. H. M., & Tin, C. (2017). Self-Recalibrating Surface EMG Pattern Recognition for Neuroprosthesis Control Based on Convolutional

Neural Network. *Frontiers in Neuroscience*, 11, 379.
<https://doi.org/10.3389/fnins.2017.00379>



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS



INSTITUTO DE INVESTIGACIÓN EN CIENCIAS BÁSICAS Y APLICADAS

Jefatura de Posgrado en Ingeniería y Ciencias Aplicadas



Cuernavaca, Morelos, 13 de septiembre de 2023.

DR. JUAN CARLOS GARCÍA CASTREJÓN
COORDINADOR DEL POSGRADO EN
INGENIERÍA Y CIENCIAS APLICADAS

PRESENTE

Atendiendo a la solicitud para emitir DICTAMEN sobre la revisión de la TESIS titulada: Diseño e implementación de una metodología para la adquisición, clasificación e interpretación de señales electromiográficas para personas con algún tipo de discapacidad o amputación de mano, que presenta el alumno **Jorge Arturo Sandoval Espino**, para obtener el título de **Doctorado en Ingeniería y Ciencias Aplicadas**.

Nos permitimos informarle que nuestro voto es **APROBATORIO**.

Atentamente
Por una humanidad culta
Una universidad de excelencia

DR. J JESÚS ESCOBEDO ALATORRE

DR. DIEGO SEURET JIMÉNEZ

DR. OMAR PALILLERO SANDOVAL

DR. J GUADALUPE VELÁSQUEZ AGUILAR

DR. MARIO LIMÓN MENDOZA

DR. ALVARO ZAMUDIO LARA

DR. JOSÉ ANTONIO MARBÁN SALGADO

Se adiciona efirma UAEM



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento firmado electrónicamente de conformidad con el ACUERDO GENERAL PARA LA CONTINUIDAD DEL FUNCIONAMIENTO DE LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS DURANTE LA EMERGENCIA SANITARIA PROVOCADA POR EL VIRUS SARS-COV2 (COVID-19) emitido el 27 de abril del 2020.

El presente documento cuenta con la firma electrónica UAEM del funcionario universitario competente, amparada por un certificado vigente a la fecha de su elaboración y es válido de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DE ESTADO DE MORELOS emitidos el 13 de noviembre del 2019 mediante circular No. 32.

Sello electrónico

JOSE ANTONIO MARBAN SALGADO | Fecha:2023-09-18 11:06:45 | Firmante

Oz2cQDENbQvnc+mND8PgmMjnyjS/detuJx3blLCBywaSXfra793rHWpDXS2gQ0xP1CN3ojwMZdudRAzjvP/AKZuj+Yz/I48KE9d36dJyV5nD9nn3YcpjwccoZIZp8ScHy6ALi8YG
Ar4bo9xqalyRsWgqJ2GAc8TQBmtJoVlHdMekTLBUHUHpaBLkOQRd0WJStlrh1wL7LfvxTo+KbRjLvlYVvtlAm8HHSkRVKutCYAGmPUk1Kl6Ji1hhQqLaPNJ8nwe0KquBagN7f
L/KCUFF5Q9SVO9hhb6CA8wTF73r3RnffQB/23JH1RmZjcVaQSKyTGXRwZHROAH4JS52NQ==

J JESUS ESCOBEDO ALATORRE | Fecha:2023-09-18 11:18:26 | Firmante

fvwQ8tzQ16eORS9LAjcxZ1sq8y1t8zaZbHeOJfY/U0YDxyphqsHFR0cGCPBA9pW60H1hdtf1uYg//afsLGCNCdPvDSqPIRct82kUioqC4Kyb2HPvodS68Fql+tEyem+yIExerBbxj
uMwsVQNCvXaj1ZEQKJHs98yY+dtgHndYhIGMu0xLZWDa0i0F9bYHV+WivYu3HVTfYqSNAgurey/GCJ7hH83H7aWqCqj3JdoemqNKB2Mm2wdkcc3FYT1Qc/I/b94zuOTnmwX
hdUJ9G0t6hvu0gMsVl1CMS6O09MkvnXOOY4TJP1NyftjSY+guXHxltGPMOWZG8d2APrdw==

ALVARO ZAMUDIO LARA | Fecha:2023-09-18 11:23:23 | Firmante

dFYxAzOsCDKfUm+Hqn66TI2X8spc+TXu6r5AJ7gETpfsKybM6FZ94N+HxHy2P8yZbHRnFvUgGpVXulwweKLCVEAbTn2efRA+KtUWo/GK+CFGsT+ZeARei3PMNuBef1/mTa9D
a+yIK6dmBEun4+YJZ4/lDU+8+DSv4QD9+xVHqzcoOPsY44T0VN4KZlwg4Ctj62l42LjYfzcn2M+6AL/UY6mrkhllfmdai9Asd+gjqrfRw1VQGt5cWkDLWYB/SwBsDntkzm6rhmsVQ
5XIHKmmisp97a5WCq2/sNN38s7jICEpCXIVfAl8H74ZC27rTNaR+MSOLXQvHJQRdpHaxlHg==

OMAR PALILLERO SANDOVAL | Fecha:2023-09-18 13:03:19 | Firmante

1ZCpb5LGE2mhwFK1Z9L04rxcZV7a09/b4mBD38tAL62IT7sySiD/xb448z8npYQHd4kXb72prEYW4fU+PYAx0k+c3jNif+2Pe7rcpPrkSoXo5Gj1MWxLAKlul+vio00CUJK03XqxCW
Jt3Lzn4Es/2p9hobWRTmiURB86lqlAuLclAhs7hc6DBS7aWkeeUyivCgRSI1moT3dlXHb/Ce7XpMj4cniudMueMHcZoS9ZjhBE2BacSlveNEj1LbcXgpbWWN9EYtaMf/UZnJrHOfAV
X+Yd+/H2qyKO+Kn3icMoktiZVgrceDrccPEOq6tcGdtnl2FQ/si6t8wwu9DX/9CgQ==

J GUADALUPE VELASQUEZ AGUILAR | Fecha:2023-09-20 10:09:37 | Firmante

VhhGvdV0ROp4v3b3wAoNaah3sxdEmn+JPzLX5wjlz0YI6jPFVJOKXkMOuGCfa5OTdJbgD4/0uisd4jMExcOprc3QLiLeDq3ISZULEigC22U0k3gMPcE6T6Rb7GAj/aTBYcFOZ0Mp
2BURumGITze3DcSynwUHGTycjR93NKGsMgm0cbelENfRDj5WRn9yg3hshz8P2/6zVCFybrIR+NMU/W7U+FiCnXASbZg1X94YlZYaZwFL2Dp2BZ6aJQrZCHdncawBXjnPwF00
M1LJQG4pyRy6f8n+O82TuVTSqafzN4BG14NeaSz0PDAHs6CG/L2Uv5Td/Od6lAsgm8qbXuog==

DIEGO SEURET JIMENEZ | Fecha:2023-09-20 16:10:25 | Firmante

OX5RV25JfG+sE+0AmcDYz+Py+LFwQ7/d6+ZA/lokPxxhkoNxV9CvV4N8MIAvAPnEW7CT3Ggd3OBUwE6toz5qeG9s4v++8ZAPfdVlcfYcY0T2cmHGIsjTz4m1WLSlhYnR19rZGp+
NqZdB1zXu+eOTOoiPajBQLVf0VmUt0nx7dNQUASabNzrGUpuB54+H4//4LeACq95wt6sM5iZlnfmgW1/wvtKDbT/6MSc17Jqs5fEjB09UsxPV2sO2um0shByLHBSu3fM6kd4A6ngG
bprhdk86bmmfUfdl1jaSB5gRIMGCEv2M1sr1+lk8pBjRoNi+JIDWSiB/1KSYnJfS3crXA==

MARIO LIMON MENDOZA | Fecha:2023-09-22 13:59:31 | Firmante

DpY6x9gXGoe84COZfAMJAE25aOknh96dj6c3JmayRplkOkF3UpTFnHOjsrKGG7LPMza5YH8JEIptCtNaAiAYZzf5csluy746s/5Ro1R4CTewSH9WQ8+CfvOgP4POogrR2RaOLJx
QfO1Mhv8wSGUUnREtw1fvvGVDq+X9SA+BYlpJBbAVDmuXWA0f9k2mQPWY8NCSZ6jTE5814dtN67jBeJ8Gw4/QJKFxnSfjXj2rKB2ms4qpNR9e5YcinR2G5hhV+vZMhh50hkRyP
6S2X6XvUmXP5PsEfaQBxq6PV5qcpwoy8DXueGBLvSAVnpKv1cMR92RHYGQb0ICb1+papZWEQ==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o
escaneando el código QR ingresando la siguiente clave:



4F9KPFvcu

<https://efirma.uaem.mx/noRepudio/JjWYGasV7miOVSKzHPSNlleInVdjcvt>

