



**UNIVERSIDAD TÉCNICA PARTICULAR DE LOJA**

*La Universidad Católica de Loja*

**ÁREA TÉCNICA**

**TÍTULO DE INGENIERO EN ELECTRÓNICA Y TELECOMUNICACIONES**

**Diseño y desarrollo de un sistema embebido de identificación de patrones de señal EMG basado en algoritmos de aprendizaje automático.**

**TRABAJO DE TITULACIÓN.**

**AUTORES:** Jaramillo Rodriguez, Leonardo Antonio

Zúñiga Vivanco, José David

**DIRECTOR:** Calderón Córdova, Carlos Alberto, Ing.

**LOJA – ECUADOR**

**2018**



*Esta versión digital, ha sido acreditada bajo la licencia Creative Commons 4.0, CC BY-NY-SA: Reconocimiento-No comercial-Compartir igual; la cual permite copiar, distribuir y comunicar públicamente la obra, mientras se reconozca la autoría original, no se utilice con fines comerciales y se permiten obras derivadas, siempre que mantenga la misma licencia al ser divulgada. <http://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>*

2018

## **APROBACIÓN DE LA DIRECTORIA DEL TRABAJO DE TITULACIÓN**

Ingeniero

Carlos Alberto Calderón Córdova

**DOCENTE DE LA TITULACIÓN**

De mi consideración:

El presente trabajo de titulación: Diseño y desarrollo de un sistema embebido de identificación de patrones de señal EMG basado en algoritmos de aprendizaje automático, ha sido orientado y revisado durante su ejecución, por cuanto se aprueba la presentación del mismo.

Loja, abril de 2018

f) .....

## DECLARACIÓN DE AUTORÍA Y CESIÓN DE DERECHOS

Nosotros Leonardo Antonio Jaramillo Rodriguez, José David Zúñiga Vivanco declaramos ser autores del presente trabajo de titulación: Diseño y desarrollo de un sistema embebido de identificación de patrones de señal EMG basado en algoritmos de aprendizaje automático, de la Titulación de Ingeniería en Electrónica y Telecomunicaciones, siendo el Ing. Carlos Alberto Calderón Córdova director del presente trabajo; y eximimos expresamente a la Universidad Técnica Particular de Loja y a sus representantes legales de posibles reclamos o acciones legales. Además, certificamos que las ideas, conceptos, procedimientos y resultados vertidos en el presente trabajo investigativo, son de mi exclusiva responsabilidad.

Adicionalmente declaramos conocer y aceptar la disposición del Art. 88 del Estatuto Orgánico de la Universidad Técnica Particular de Loja que en su parte pertinente textualmente dice: “Forman parte del patrimonio de la Universidad la propiedad intelectual de investigaciones, trabajos científicos o técnicos y tesis de grado o trabajos de titulación que se realicen con el apoyo financiero, académico o institucional (operativo) de la Universidad”

f. ....

Autor: Leonardo Antonio Jaramillo Rodriguez

Cédula: 1104498025

f. ....

Autor: José David Zúñiga Vivanco

Cédula: 1105876112

## DEDICATORIA

Dedico este trabajo de titulación:

A mis padres, por haberme brindado todo su apoyo, por enseñarme a tomar mis decisiones con responsabilidad, fortaleza y afrontar los problemas de la vida con entereza. Y, a todos mis familiares y amigos, que me han motivado y ayudado en mis estudios.

**Leonardo Jaramillo**

Dedico este trabajo de titulación a:

La memoria de mi querido y ejemplar padre, Luis Zúñiga (QEPD), a pesar de que hoy no te encuentres conmigo físicamente, te llevo siempre presente en mis pensamientos por todos los buenos consejos y el apoyo que me supiste brindar durante toda mi vida para alcanzar mis metas sin importar las dificultades que se pudieran presentar. Por formarme con buenos sentimientos, hábitos y valores que me han ayudado a salir adelante en momentos de dificultad. Te dedico a ti este logro alcanzado porque sé cuánto anhelabas verme convertido en “todo un profesional”, como solías decir.

A mi amada madre Máxima Vivanco por ser una gran mamá y pilar fundamental en mi vida, por demostrarme tu cariño y apoyo ilimitado e incondicional sin importar nuestras diferencias, por haberme formado como un hombre de bien, por la paciencia y el amor que siempre me has tenido, y lo más importante por estar conmigo en los momentos más difíciles, cuando más lo he necesitado.

A mi hermano Lucho, por tu empeño y constancia de querer hacer de mí una mejor persona, por estar a mi lado brindándome consejos y guiándome en algunas decisiones de mi vida.

A toda mi familia, por todos los esfuerzos que hicieron por mí, desde mi infancia, por todas las veces que dejaron de lado sus necesidades para suplir las mías, por la confianza que siempre depositaron en mí, por sus palabras de aliento y buenos deseos.

A todos mis amigos, a quienes considero personas muy valiosas por estar a mi lado en las buenas y en las malas, por todas las experiencias vividas y por todo su apoyo que me han sabido brindar.

**José David Zúñiga**

## **AGRADECIMIENTO**

A Dios por habernos guiado a través de nuestras vidas hasta llegar a obtener este logro.

A nuestros padres y familiares por darnos todo el apoyo y motivación necesaria durante nuestra formación profesional.

A nuestro director de tesis Ing. Carlos Calderón por su colaboración y dedicación en el desarrollo de este trabajo de titulación.

A nuestros amigos y demás personas que ayudaron en las diferentes pruebas requeridas para la realización de este trabajo.

A nuestros profesores por impartirnos sus conocimientos y brindarnos enseñanzas acerca de la vida profesional.

A la universidad por habernos brindado la oportunidad de seguir nuestra carrera profesional, que nos servirá para realizarnos en nuestra vida particular a fin de contribuir con nuestros servicios a la sociedad.

## ÍNDICE DE CONTENIDOS

CARÁTULA .....	i
APROBACIÓN DE LA DIRECTORIA DEL TRABAJO DE TITULACIÓN .....	ii
DECLARACIÓN DE AUTORÍA Y CESIÓN DE DERECHOS.....	iii
DEDICATORIA .....	iv
AGRADECIMIENTO .....	v
ÍNDICE DE CONTENIDOS.....	vi
ÍNDICE DE FIGURAS.....	ix
ÍNDICE DE TABLAS .....	xi
RESUMEN.....	1
ABSTRACT .....	2
OBJETIVOS .....	3
Objetivo General:.....	3
Objetivos Específicos:.....	3
INTRODUCCIÓN.....	4
CAPÍTULO 1.....	7
GENERALIDADES.....	7
1.1. Arquitectura del hardware. ....	8
1.1.1. Estructura del antebrazo. ....	8
1.1.1.1. Huesos.....	8
1.1.1.2. Músculos.....	8
1.1.1.2.1. Músculos Superficiales - Cara Anterior. ....	9
1.1.1.2.2. Músculos Superficiales – Cara Posterior.....	10
1.1.1.3. Nervios.....	10
1.1.2. Electromiografía.....	12
1.1.3. Electrodo para EMG.....	12
1.1.3.1. Electrodo de alambre fino.....	12
1.1.3.2. Electrodo superficial.....	13
1.1.4. Acondicionamiento de la señal.....	13
1.1.4.1. Etapa de pre-amplificación.....	13
1.1.4.2. Etapa de Filtrado.....	14
1.1.4.3. Etapa de Rectificado.....	14
1.1.5. Sensores para electromiografía.....	14
1.1.5.1. MyoWare Muscle Sensor.....	14

1.1.5.2.	Muscle sensor V3.....	15
1.1.5.3.	Surface EMG Sensor SX230.....	15
1.1.5.4.	Grove-EMG Sensor.....	15
1.1.6.	Procesamiento de la señal EMG.....	16
1.1.6.1.	Arduino Pro-Mini.....	16
1.1.6.2.	Arduino DUE.....	16
1.1.7.	Prototipo de Prótesis.....	17
1.2.	Arquitectura del Software.....	17
1.2.1.	Captura y almacenamiento de señales mioeléctricas(EMG).....	18
1.2.2.	Red neuronal artificial.....	18
1.2.2.1.	Neurona Artificial.....	18
1.2.2.2.	Arquitectura de la red neuronal.....	21
1.2.2.3.	Feedforward.....	21
1.2.2.4.	Redes Multicapa.....	22
1.2.3.	Algoritmo de aprendizaje.....	24
1.2.3.1.	Función de Error.....	24
1.2.3.2.	Algoritmo Backpropagation.....	25
1.2.4.	Entrenamiento.....	26
CAPÍTULO 2.....		28
DISEÑO DEL SISTEMA DE RECONOCIMIENTO DE PATRONES.....		28
2.1.	Diseño del sistema de reconocimiento de patrones.....	29
2.1.1.	Captura y almacenamiento de señales EMG.....	29
2.1.2.	Diseño de la red neuronal artificial.....	29
2.1.3.	Aprendizaje del sistema.....	31
2.1.3.1.	Algoritmo de Backpropagation.....	31
2.1.4.	Entrenamiento.....	33
CAPÍTULO 3.....		35
IMPLEMENTACIÓN DE LOS SISTEMAS DE ADQUISICIÓN DE SEÑALES EMG Y RECONOCIMIENTO DE PATRONES.....		35
3.1.	Implementación del Sistema de sistemas de adquisición de señales EMG.....	36
3.1.1.	Tarjeta de acondicionamiento.....	36
3.1.2.	Selección de Electroodos.....	37
3.1.3.	Posicionamiento de los electrodos.....	39
3.1.3.1.	Posicionamiento basado en nervios del antebrazo.....	40
3.1.3.2.	Posicionamiento basado en grupos musculares.....	45
3.1.4.	Ajuste de la señal EMG.....	47

3.1.5.	Selección de movimiento y secuencia de patrones .....	48
3.2.	Implementación del Módulo de reconocimiento de patrones .....	49
3.2.1.	Implementación del módulo de captura y almacenamiento de las señales EMG	50
3.2.2.	Implementación de la red neuronal artificial .....	53
3.2.2.1.	Función de establecimiento de parámetros iniciales.....	53
3.2.2.2.	Función RNA .....	54
3.2.1.	Implementación del algoritmo de backpropagation.....	56
3.2.2.	Implementación del algoritmo de entrenamiento .....	56
CAPÍTULO 4.....		59
EVALUACIÓN DEL DESEMPEÑO DEL SISTEMA EMBEBIDO.....		59
4.1.	Metodología utilizada .....	60
4.1.1.	Banco de muestras .....	61
4.2.	Validación del sistema de reconocimiento de patrones .....	62
4.2.1.	Validación cruzada.....	63
4.2.2.	Validación online .....	64
4.3.	Análisis de resultados .....	64
4.3.1.	Validación cruzada.....	64
4.3.2.	Validación online .....	65
CONCLUSIONES .....		68
RECOMENDACIONES.....		69
Bibliografía.....		70
ANEXOS.....		75
ANEXO A.....		76
ANEXO B.....		77
ANEXO C .....		78
ANEXO D .....		90

## ÍNDICE DE FIGURAS

Figura 1.1 Arquitectura Hardware Fuente: Autores Elaborado: Autores .....	8
Figura 1.2 Músculos superficiales del antebrazo Fuente: Autores Elaboración: Autores.....	9
Figura 1.3 Inervación de la mano Fuente: [34] Elaboración: Autores .....	11
Figura 1.4 Nervios del antebrazo Fuente: [35] Elaboración: Autores.....	11
Figura 1.5 a) Myoware Muscle Sensor; b) Muscle Sensor V3; c) Surface EMG Sensor SX230; d) Groove-EMG Sensor Fuente: [46], [47], [48], [49]. Elaboración: Autores.....	16
Figura 1.6 a) Arduino Pro Mini; b) Arduino DUE Fuente: [51], [52]. Elaboración: Autores ....	17
Figura 1.7 Arquitectura software del sistema de reconocimiento de patrones .....	18
Figura 1.8 Neurona natural .....	19
Figura 1.9 Parámetros de una neurona artificial.....	19
Figura 1.10 Funciones de transferencia más usadas .....	21
Figura 1.11 Red neural artificial Multicapa .....	22
Figura 1.12 Límite de decisión de una mono red (a). Límite de decisión de una red con dos capas (b). límite de decisión arbitraria generada por una red de tres capas (c) .....	23
Figura 1.13 Notación de Red neuronal de 3 capas .....	23
Figura 1.14 Esquema del aprendizaje de una red neuronal artificial .....	24
Figura 1.15 Esquema del funcionamiento del algoritmo Backpropagation .....	26
Figura 1.16 Error en función del número de épocas .....	27
Figura 2.1 Topología de Red neuronal multicapa.....	29
Figura 2.2 Función de transferencia sigmoide.....	30
Figura 2.3 Esquema de la RNA implementada. ....	31
Figura 2.4 Diagrama del algoritmo de Backpropagation.....	32
Figura 2.5 Error en función de los pesos de la red neuronal .....	32
Figura 2.6 Diagrama del entrenamiento .....	33
Figura 3.1 Señal EMG-MyoWare Muscle Sensor .....	36
Figura 3.2 ElectrodoH124SG Coviden. ....	37
Figura 3.3 Elaboración de electrodos a base de tela conductiva.....	38
Figura 3.4 Electrodos de Cobre .....	38
Figura 3.5 a) Diseño de prótesis para creación de molde de yeso. b) Horno de luz infrarroja y lámina de PMMA. c) fusión de molde de yeso con la lámina de PMMA. d) Prueba de prótesis de PMMA .....	39
Figura 3.6 División del antebrazo.....	40
Figura 3.7 Disposición de electrodos sobre los nervios del antebrazo .....	41
Figura 3.8 Tipos de contextura corporal.....	51
Figura 3.9 a) Diagrama de la función para el entrenamiento. b) Diagrama de la función para la red embebida. ....	54
Figura 3.10 Error de memoria en el atmega 328.....	55
Figura 3.11 Esquema del módulo de identificación de patrones. ....	55
Figura 3.12 MSE en función del número de épocas.....	57
Figura 3.13 Diagrama del funcionamiento de la función de entrenamiento implementada. ..	58
Figura 4.1 Diagrama de la metodología utilizada para la formación del banco de muestras	60
Figura 4. 2 Estación de validación .....	63
Figura 4.3 Resultados de la validación cruzada .....	64

Figura 4.4 Comparación de exactitud entre la validación cruzada y validación online..... 67

## ÍNDICE DE TABLAS

Tabla 3.1 Movimientos realizados para la acción de cara nervio .....	41
Tabla 3.2 Señal EMG obtenida del nervio cubital.....	42
Tabla 3.3 Señal obtenida del nervio medio .....	43
Tabla 3.4 Señal EMG obtenida del nervio radial .....	44
Tabla 3.5 Movimientos realizados para la acción de cada movimiento .....	45
Tabla 3.6 Señales EMG obtenidas de los músculos superficiales del antebrazo .....	45
Tabla 3.7 Comparación de las señales para el posicionamiento.....	47
Tabla 3.8 Selección de secuencia de patrones.....	48
Tabla 3.9 Resultados de las pruebas de la ventana de tiempo .....	51
Tabla 3.10 Configuraciones de la RNA con distintos tiempos de muestreo.....	53
Tabla 4.1 Características de usuarios de prueba para la extracción de señales EMG .....	61
Tabla 4.2 Ejemplo de señal EMG extraída para el banco de señales .....	62
Tabla 4.3 Asignación de las salidas de la RNA.....	63
Tabla 4.4 Resultados de la validación cruzada .....	65
Tabla 4.5 Resultados de la validación online .....	65
Tabla 4.6 Matriz de confusión para el peor resultado.....	66
Tabla 4.7 Matriz de confusión para el mejor resultado .....	66

## RESUMEN

Este trabajo forma parte del proyecto de investigación "Mano Esperanza". Se ha implementado un sistema embebido de reconocimiento de patrones, utilizando señales electromiográficas (EMG) detectadas en tiempo real para el control de una prótesis robótica. El trabajo se ha dividido en dos etapas: la etapa de extracción de señales EMG que consistió en la investigación y aplicación de los distintos métodos de adquisición y acondicionamiento de señales EMG y la etapa destinada al reconocimiento de patrones, donde se investigó algoritmos de redes neuronales y algoritmos de aprendizaje supervisado. Además, se diseñó e implementó un algoritmo para el entrenamiento y validación del sistema.

Los resultados obtenidos de la clasificación de patrones en la etapa de validación se los presenta a través de matrices de confusión y porcentajes de exactitud, para demostrar la efectividad del sistema. Se realizó pruebas de validación en 12 personas voluntarias sin discapacidad motriz, obteniendo un porcentaje de acierto del 97%. Los resultados demostraron que el sistema es capaz de controlar la ejecución de cinco movimientos de la prótesis de mano robótica.

**PALABRAS CLAVES:** Redes neuronales artificiales, Sistema embebido, Señales EMG, Backpropagation.

## **ABSTRACT**

This work is part of the “Mano Esperanza” research project. An embedded pattern recognition system has been implemented, using electromyography (EMG) signals detected in real time to control a robotic prosthesis. The work has been divided in two stages: the stage of extraction of EMG signals that consisted in the investigation and application of the distinct methods of acquisition and conditioning of EMG signals and the stage intended for pattern recognition, where neural network algorithms and supervised learning algorithms were investigated. In addition, an algorithm was designed and implemented to train and validate the system.

The results obtained from the patterns classification in the validation stage are presented through confusion matrices and percentages of accuracy to show the effectivity of the system, obtaining a success rate of 97%. The validation tests have been accomplished on 12 people without motor disabilities. The results show that the system was able to control the execution of five movements of the robotic hand prosthesis.

**KEYWORDS:** Artificial Neural Network, embedded system, EMG signal, backpropagation.

## **OBJETIVOS**

### **Objetivo General:**

Diseñar y desarrollar un sistema embebido de identificación de patrones de señal EMG basado en algoritmos de aprendizaje automático

### **Objetivos Específicos:**

1. Diseñar la arquitectura hardware-software-firmware del sistema de adquisición e identificación de señales EMG.
2. Diseñar un sistema de identificación de patrones de señal EMG basado en la técnica de redes neuronales artificiales, fases de entrenamiento y reconocimiento.
3. Diseñar y aplicar una metodología para el desarrollo de una ANN en un sistema embebido.
4. Evaluar el desempeño del sistema embebido de identificación de patrones de señal EMG, mediante matrices de confusión u otros métodos equivalentes.

## INTRODUCCIÓN

La calidad de vida está directamente relacionada con el estado funcional e independencia [1]. Por lo tanto, la pérdida de una extremidad superior tiene un efecto negativo que repercute en aspectos psicológicos, sociales y funcionales [2]. Ante esta problemática la electrónica, la informática y la robótica, están permitiendo elaborar un conjunto de soluciones tecnológicas para combatir estas deficiencias y conseguir un mayor grado de autonomía personal [3], una de estas soluciones es el uso de prótesis robóticas [4].

En [5], se demostró el rechazo al uso de prótesis debido a factores como la funcionalidad y comodidad, recomendando que: “La investigación futura debe centrarse en el desarrollo continuo de prótesis más cómodas y funcionales”. En el Ecuador el índice de personas con discapacidad de amputación de miembro superior es de 200.240 de los cuales solo 31.926 se encuentran laboralmente activas según el Consejo Nacional para la igualdad de discapacidades (CONADIS) [6]. En base a lo expresado anteriormente, mediante la electromiografía se puede diseñar un sistema de control simple y amigable [7], con el fin de brindar mayor integridad y capacidad laboral al usuario.

Para el diseño de un sistema de control existen varias técnicas como son: Redes neuronales artificiales (RNA), Clasificador Bayesiano, Lógica difusa, Sistemas Neuro-fuzzy, entre otros [8].

Los autores de [9] utilizaron RNA, Redes neuronales dinámicas difusas y sistemas de inferencia neuro-difusos adaptativos como clasificadores y varios métodos de extracción de características de las señales EMG, calculando el rendimiento de cada una de las técnicas de extracción de características en cada clasificador, en este trabajo no realizaron una implementación hardware del proyecto.

En [10] se compara la precisión de clasificación de la técnica análisis discriminante lineal con varios métodos de extracción de características. El método con mayor precisión es el método AR (Autoregressive). El análisis del nivel fuerza de las contracciones determinó que los niveles de fuerza del entrenamiento y las pruebas del clasificador deben ser iguales para disminuir errores en la clasificación.

En [11] usaron las características en el dominio del tiempo de las señales EMG para la clasificación de patrones, comparan los resultados de clasificación y calculan el tamaño de memoria necesaria para almacenar las características. El método AR ocupa mayor espacio de almacenamiento.

En [12], mediante un perceptrón multicapa, realizaron un análisis de los componentes principales para sintetizar la información de entrenamiento, el sistema de clasificación fue

programado en MATLAB y embebido en un DSP (Digital Signal Processor). Los elementos usados en la implementación del proyecto no están orientados al bajo consumo de energía. En [13], utilizando máquinas de vectores de soporte como clasificador, extrajeron las características en función del tiempo de las señales EMG para reducir los datos de entrada del clasificador, el cual está implementado en MATLAB. Los datos adquiridos son procesados en un computador en la fase de entrenamiento y validación del clasificador. La extracción de características resulta ser un proceso que demanda de alto costo computacional por lo que algunos autores como en [14] y [15] prefieren hacerlo a través de un computador. Para la clasificación de patrones en [14] utilizaron una RNA en la que su entrenamiento lo realizaron utilizando vectores extraídos de diferentes pruebas, mientras que en [15] utilizaron un clasificador de mínima distancia y un clasificador (KNN). Recomiendan para investigaciones futuras se aumente el número de neuronas en la capa oculta y el número de movimientos para tener un resultado más exitoso. Cabe mencionar que estos trabajos no han sido implementados en un sistema embebido. En [16], se diseña un clasificador para tres movimientos utilizando dos músculos del antebrazo. La extracción de características la realiza utilizando la Transformada Rápida de Fourier (FFT) y para la clasificación lo realiza a partir de umbrales de activación. En este proyecto se utiliza un kit de desarrollo DE2-70 que cuenta con un FPGA y obtiene una tasa de identificación del 87%. En [17] y [18] desarrollaron un sistema para la caracterización y clasificación de señales EMG utilizando parámetros de tiempo y frecuencia. La clasificación de patrones es llevada a cabo mediante un perceptrón multicapa (MLP). De los datos obtenidos, el 60% fueron empleados para el entrenamiento y el 40% para validación. La extracción de este tipo de características conlleva un considerable aumento en costo computacional. En los trabajos [19] y [20] implementaron un prototipo de prótesis robótica con un sistema de reconocimiento de patrones basado en RNA utilizando señales EMG y un MLP. El MLP fue implementado mediante el Toolbox de RNA de MATLAB. El entrenamiento y validación del sistema lo llevaron a cabo con 20 muestras por cada clase, obteniendo un éxito del 95%. En el presente trabajo se realiza el diseño e implementación de un sistema embebido de reconocimiento de patrones en tiempo real, con el fin de reducir el uso de componentes externos en el proyecto de investigación mano esperanza. El sistema está basado en el algoritmo de aprendizaje supervisado backpropagation. La implementación se realiza mediante los lenguajes de programación C/C++ y se prueba en las arquitecturas de 8 bits y 32 bits. Para la extracción de las señales EMG se ha desarrollado un firmware incluido al sistema embebido con sensores "MyoWare Muscle Sensor" y dos tipos de electrodos superficiales: electrodos de gel y electrodos secos.

El trabajo está organizado en cuatro capítulos, en el primer capítulo se detalla los aspectos generales, conceptos, definiciones y terminologías utilizadas para una mejor comprensión del trabajo realizado. En el segundo capítulo se detalla cada uno de los módulos que conforman el diseño del sistema de identificación de patrones. En el tercer capítulo se procede a la implementación del sistema de adquisición de señales EMG junto con el sistema de reconocimiento de señales. En el cuarto capítulo se analizan los resultados y se evalúa el desempeño del sistema de identificación de patrones. Finalmente, se muestran las conclusiones y recomendaciones obtenidas en el desarrollo del trabajo.

**CAPÍTULO 1**  
**GENERALIDADES**

## 1.1. Arquitectura del hardware.

En la Figura 1.1 se muestra la arquitectura hardware del sistema para la obtención de señales EMG, la cual esta subdividida en 4 bloques fundamentales para el procesamiento de estas señales. Cada una de estas etapas serán descritas en la siguiente sección.



Figura 1.1 Arquitectura Hardware

Fuente: Autores

Elaborado: Autores

### 1.1.1. Estructura del antebrazo.

Al igual que otras partes del cuerpo humano, el antebrazo se encuentra constituido por una serie de huesos, músculos, nervios y vasos sanguíneos que en conjunto realizan sus funciones básicas.

#### 1.1.1.1. Huesos.

El esqueleto del antebrazo se encuentra formado por dos huesos llamados radio y cúbito

- **Radio:** Es un hueso de forma alargada, parte del exterior del codo para llegar al pulgar a nivel de la muñeca [21].
- **Cúbito:** Se encuentra situado en la parte interna del antebrazo. Es un hueso largo, par y no simétrico, ligeramente inclinado de afuera a adentro [22].

#### 1.1.1.2. Músculos.

Para el estudio de los músculos que se encuentran en el antebrazo, se ha decidido realizarlo en dos secciones, plano superficial-cara anterior y plano superficial-cara posterior (Figura 1.2). No se estudiará los músculos del plano profundo porque los electrodos utilizados son superficiales y no es posible la lectura de señales EMG [23].

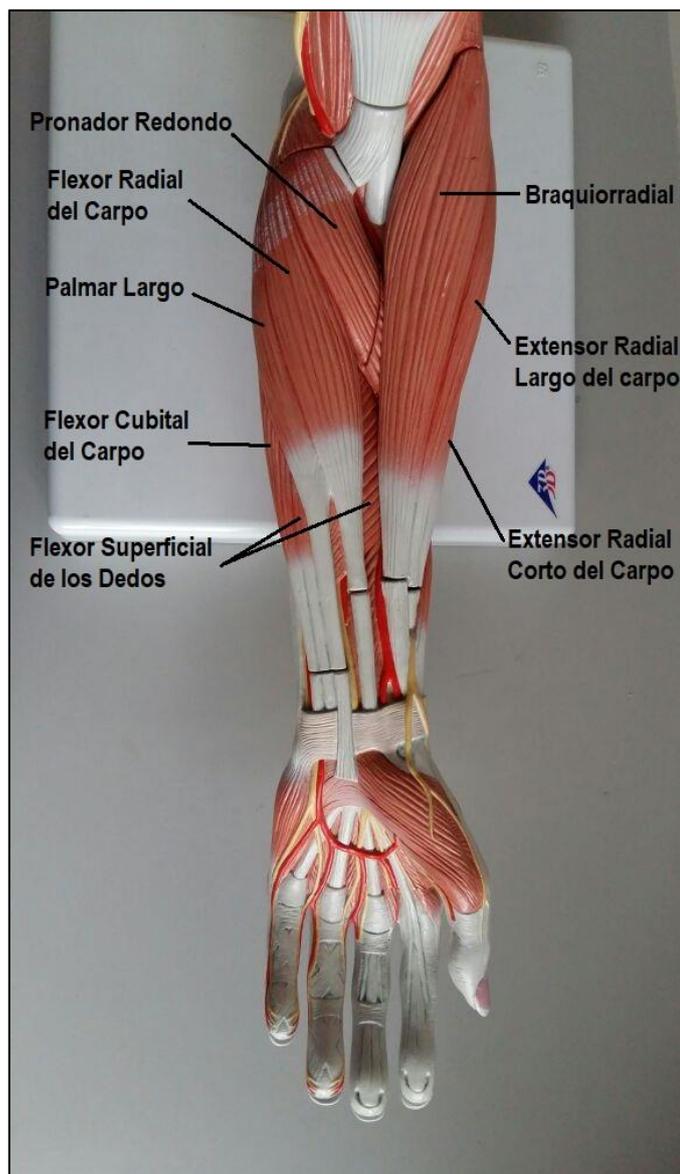


Figura 1.2 Músculos superficiales del antebrazo  
Fuente: Autores  
Elaboración: Autores

#### 1.1.1.2.1. Músculos Superficiales - Cara Anterior.

- **Pronador redondo:** Se sitúa al lado más lateral de los epicondíleos, que atraviesa de forma diagonal la cara anterior del antebrazo. Se origina en la cabeza humeral (epicóndilo medial) y la cabeza cubital (borde medial de la apófisis coronoides). Su función es la pronación del radio sobre el cúbito, es decir ayuda en la flexión del antebrazo sobre el brazo [23], [24].
- **Flexor radial del carpo:** Es un músculo fusiforme, aplanado de anterior a posterior. Se encuentra en la cara anterior del antebrazo, en dirección del pronador redondo y

palmar largo. Su función es la flexión y abducción de la mano sobre el antebrazo [25], [26].

- **Palmar largo:** Este músculo se origina en el epicóndilo medial del húmero, y se ubica junto al supinador largo. Su función es la flexión de la muñeca sobre el antebrazo [23].
- **Flexor cubital del carpo:** es un músculo ancho y grueso que se origina en la cabeza humeral y en el borde del cúbito (cabeza cubital). Posee dos cabezas que se unen en su extremo y por medio de un arco fibroso pasa el nervio cubital. Su función es la flexión y aducción de la mano [27], [28].
- **Flexor superficial de los dedos:** Se encuentra entre el palmar mayor y el palmar menor, en la porción anterior del antebrazo. Se origina en tres cabezas, cabeza humeral, cabeza cubital y cabeza radial, y distalmente a través de cuatro tendones en las falanges en los últimos cuatro dedos. Su función es la flexión de las falanges y de la muñeca [23], [29].

#### 1.1.1.2.2. Músculos Superficiales – Cara Posterior.

- **Braquiorradial:** es un músculo aplanado, muscular en sus dos tercios superiores y tendinoso en el primer tercio inferior. Se origina en la cresta supracondílea, desde ahí se dirige a lo largo de la cara lateral del antebrazo hasta el extremo inferior del radio. Su función es la flexión del antebrazo sobre el brazo [30].
- **Extensor radial largo del carpo:** es un músculo largo y carnoso situado por debajo del braquiorradial y por encima del extensor radial corto del carpo (borde lateral del antebrazo). Su función es la extensión de la muñeca [31].
- **Extensor radial corto del carpo:** Músculo grueso y semipenniforme, formado de músculo en la parte superior y tendinoso en la parte inferior. Se origina en el epicóndilo extremo humeral y se encuentra en la cara lateral del antebrazo y se extiende desde el epicóndilo hasta la base del tercer metacarpiano. Su función es la extensión y abducción de la muñeca [32], [33].

#### 1.1.1.3. Nervios.

Los nervios que inervan los diferentes músculos y estructuras del antebrazo son una rama del plexo braquial en el cuello, estos son el nervio radial, nervio medio, y nervio cubital (Figura 1.3). Los nervios mencionados, inervan ciertas regiones de la mano, como se puede observar en la Figura 1.4.

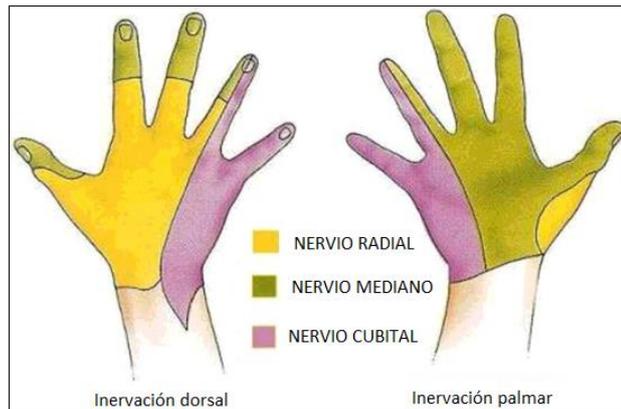


Figura 1.3 Inervación de la mano

Fuente: [34]

Elaboración: Autores

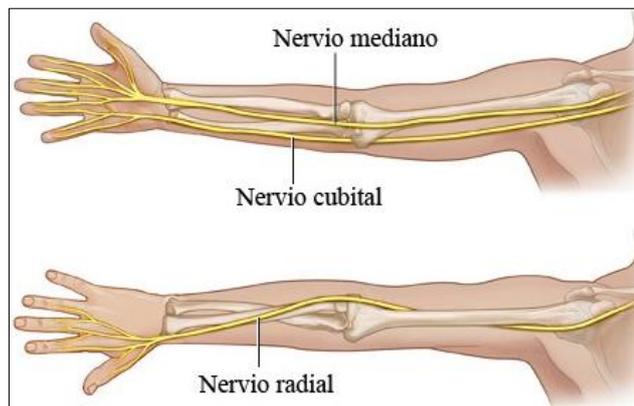


Figura 1.4 Nervios del antebrazo

Fuente: [35]

Elaboración: Autores

- **Nervio Radial:** inicia por detrás de la arteria axilar y anterior a los músculos subescapular y redondo mayor. Al salir de la axila, el nervio pasa entre la arteria braquial y la cabeza larga del tríceps, para descender acompañado de la arteria braquial profunda. Mientras se desplaza pasa por el codo para llegar al antebrazo y se ubica entre los músculos extensores superficiales y profundos del antebrazo, donde emite pequeñas ramas para los músculos extensor común de los dedos, y extensor ulnar del carpo [36], [37].
- **Nervio medio:** proviene del plexo braquial e inerva todos los músculos flexores del antebrazo, menos el músculo flexor ulnar del carpo. Desciende por el brazo medial junto a la arteria braquial. Sigue hasta la fosa cubital por fuera del tendón del bíceps y pasa al antebrazo entre las dos cabezas del pronador redondo. En el antebrazo cruza la arcada tendinosa y se sitúa por debajo del flexor común superficial de los dedos, unido a la superficie profunda de este. En el antebrazo inerva al pronador redondo, palmar mayor y al flexor común superficial de los dedos. De este se desprende el nervio interóseo anterior y se sitúa entre el flexor común profundo de

los dedos y el flexor largo del pulgar, para terminar inervando el pronador cuadrado [36], [38].

- **Nervio cubital:** Es un nervio sensitivo que inerva la mayoría de los músculos de la mano y recoge la sensibilidad de la piel de la mitad cubital de la palma y dorso de la mano. Se desplaza junto con el nervio mediano por el lado posteromedial del húmero. Pasa por el codo, por el surco olecraneano, entra al compartimiento flexor del antebrazo a través de las cabezas del flexor ulnar del carpo. Luego se desplaza al músculo flexor ulnar del carpo. Termina en la muñeca por delante del ligamento ulnar del carpo y por fuera del huso piriforme. Se divide en dos ramas, la rama superficial y la rama profunda que proporciona inervación motora a la mayoría de los músculos de la mano [34].

### **1.1.2. Electromiografía.**

Es la técnica utilizada para medir los niveles de activación en los músculos por medio de los potenciales de acción, generados para realizar la contracción de fibras musculares. Este registro puede realizarse por medio de electrodos, ya sea insertados en el músculo o superficiales. Los electrodos de inserción son destinados para uso clínico, mientras que los electrodos superficiales son utilizados para el estudio de destrezas motoras y análisis de EMG [39].

La base del uso de la EMG en el estudio cuantitativo es la relación entre la diferencia de potencial de acción, tensión muscular y fuerza generada por el músculo, por lo que las mediciones de señales EMG pueden relacionarse con la fuerza muscular [40].

En la electromiografía se registra diferencias de potencial eléctrico que se encuentran en un rango de 50 $\mu$ V a 5mV, por la cual es necesario emplear una etapa de amplificación. La EMG tiene variedad de aplicaciones, en este trabajo nos enfocaremos en estas señales como señal de control para prótesis mioeléctrica [41].

### **1.1.3. Electrodo para EMG.**

#### **1.1.3.1. Electrodo de alambre fino.**

Son electrodos de alambre que se introducen en el músculo mediante una aguja. Ideales para estudios de movimientos ya que dan una información global de la actividad muscular con gran exactitud. Sus principales ventajas son: el registro de un músculo específico permite llegar a músculos profundos, aísla los músculos, y registrar músculos pequeños.

Sus inconvenientes son: la molestia que generan al ser introducidos, aumentan la tensión en los músculos y pueden generar calambres [42].

#### **1.1.3.2. Electroodos superficiales.**

Son electroodos que se colocan sobre la piel en el músculo a examinar, poseen baja impedancia y presentan un comportamiento estable. La SENIAM (Surface EMG for a non-invasive assessment of muscles) recomienda que se debe utilizar electroodos de referencia superficiales formados de una capa de Ag/AgCl (plata/cloruro de plata) cubierto de gel conductor y que el tamaño de los electroodos no supere los 10mm. Estos electroodos proporcionan una transición estable de la señal, con ruido relativamente bajo y se encuentran más disponibles en el mercado [43].

En electromiografía se utiliza electroodos bipolares que consiste en el uso de dos electroodos de las mismas características, separados 20mm uno del otro. Esta distancia no debe variar al realizar algún movimiento ya que puede generar variaciones en las características de la señal EMG. Para su ubicación, se recomienda realizarla entre el músculo a examinar y el tendón, siempre en sentido longitudinal de las fibras musculares. Además, se debe colocar un electroodo neutro o de tierra que se lo localiza sobre un tejido eléctricamente inactivo [41]. Estos electroodos superficiales no producen dolor y son muy fáciles de colocar; Las señales son más reproducibles y son muy buenos para los estudios de movimientos. Cabe mencionar que al ser electroodos superficiales no se tiene una zona específica para la extracción de la señal y por lo tanto aumenta probabilidad de registrar señales de otros músculos adyacentes (cross talk) [44].

#### **1.1.4. Acondicionamiento de la señal.**

La diferencia de potencial que existe entre los electroodos se encuentra en micro voltios, por lo que es necesario realizar una pre-amplificación de la señal extraída por los sensores. Una vez resuelto el problema de pre-amplificación es conveniente realizar una etapa de filtrado con la finalidad de limpiar la señal que se ha recolectado y que ha sido amplificada. Una vez aplicada una etapa de pre-amplificación y una etapa de filtrado, se tiene una etapa de rectificación [39].

##### **1.1.4.1. Etapa de pre-amplificación.**

En una configuración bipolar y siguiendo las recomendaciones de la SENIAM, en la lectura de las señales EMG no se logra obtener valores iguales en repetidas lecturas, ya que

mientras se repite las mediciones incrementa la fatiga muscular, la cual hace que la amplitud de la señal varíe. Al tener dos electrodos para la medición se produce una diferencia de potencial mínima. En esta etapa se amplifica la diferencia entre los dos electrodos considerando que, si existe ruido también se amplificará [43].

El amplificador de instrumentación debe estar lo más cerca posible a los sensores de medición (electrodos) para evitar la inversión de ruido en los conductores. Es un amplificador de diferencias, es decir que la salida es proporcional en forma lineal a la diferencia de sus entradas. De este modo cada entrada representa un electrodo de valor referencial al tercer electrodo (electrodo de referencia) [45].

#### **1.1.4.2. Etapa de Filtrado.**

El filtrado analógico son dispositivos electrónicos que eliminan frecuencias seleccionadas con la finalidad de eliminar señales espurias y tener una señal limpia para su respectivo análisis. Basándonos en las recomendaciones del SENIAM se establece que las señales mioeléctricas de interés se encuentran en el rango de frecuencias de 10 a 500 Hz [43].

Los filtros activos son circuitos formados con resistencias, capacitores y amplificadores operacionales, que permiten el paso solo de ciertas frecuencias seleccionadas desde la entrada hasta la salida del filtro. En esta etapa se utiliza un filtro pasa bajas y pasa altas, es decir, el filtro pasa bajas permite el paso de bajas frecuencias y el filtro pasa altas permite el paso de altas frecuencias [45].

#### **1.1.4.3. Etapa de Rectificado.**

La extracción de características de los potenciales de acción se obtiene de la parte positiva del semiciclo de la señal y por esta razón es necesario rectificar la señal para poder analizar todos los datos que la conforman, transformando así una señal bipolar en una señal monopolar. Existen dos tipos de rectificadores: rectificador de media onda, y rectificador de onda completa. Es recomendable utilizar un rectificador de onda completa para conservar toda la información de la señal [45].

#### **1.1.5. Sensores para electromiografía.**

##### **1.1.5.1. MyoWare Muscle Sensor.**

Es un sensor portátil que mide, amplifica, filtra, y rectifica e integra la actividad eléctrica generada por las células musculares de un músculo, y produce una señal de salida

analógica que puede ser leída por algún microcontrolador. A medida que el grupo muscular objetivo se flexiona, el voltaje de salida del sensor aumenta. La relación exacta entre el voltaje de salida y la actividad muscular se puede ajustar con un potenciómetro de ganancia integrado. Para adherirse a la piel, la tarjeta requiere de tres electrodos que se insertan en los conectores tipo snap, lo que facilita la conexión y separación de electrodos. Dos conectores se encuentran colocados en la PCB y el tercero se encuentra al final del cable del electrodo de referencia como se muestra en la Figura 1.5(a) [46].

#### **1.1.5.2. Muscle sensor V3.**

Es una tarjeta de acondicionamiento para medir actividad muscular, por sus características es utilizado en el campo médico, y en la actualidad con la ayuda de microcontroladores y de los circuitos integrados, se puede utilizar en cualquier sistema de control automático. Además, esta tarjeta permite medir y modificar la actividad muscular. Los electrodos se conectan mediante conectores tipo snap a tres cables, como se observa en la Figura 1.5(b), los cables se conectan a la tarjeta muscle sensor V3 mediante un conector TRRS [47].

#### **1.1.5.3. Surface EMG Sensor SX230.**

Como se aprecia en la Figura 1.5(c), es una sonda activa de fácil uso, que proporciona una señal EMG excelente. Posee un amplificador lo que significa que requiere poca o ninguna preparación de la piel y no requiere de geles conductores, simplemente se aplica el electrodo al músculo que se desea examinar con una cinta adhesiva troquelada de doble cara de grado médico. Se conecta al sistema portátil DataLOG y al sistema DataLINK para recoger, suavizar e integrar la señal EMG. Estos sistemas permiten recopilar información en tiempo real en un software de terceros [48].

#### **1.1.5.4. Grove-EMG Sensor.**

Permite detectar pequeños pulsos eléctricos producidos por la actividad muscular, y los transforma en una señal reconocible para alguna tarjeta de adquisición de datos. El voltaje de salida va desde 1.5 hasta 3.3 voltios, siendo 1.5 voltios cuando se encuentra en reposo, y 3.3 cuando se ha realizado alguna actividad muscular. En la Figura 1.5(d) se aprecia el sensor grove [49].

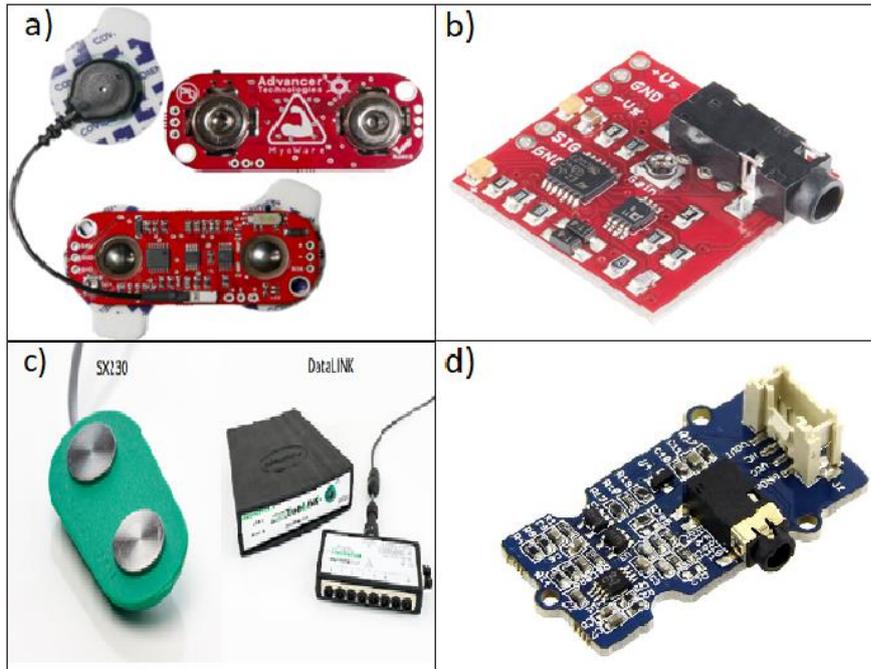


Figura 1.5 a) Myoware Muscle Sensor; b) Muscle Sensor V3; c) Surface EMG Sensor SX230; d) Groove-EMG Sensor  
Fuente: [46], [47], [48], [49].  
Elaboración: Autores

### 1.1.6. Procesamiento de la señal EMG.

En este proyecto se utilizó la tarjeta de procesamiento Arduino Pro mini ya que por sus dimensiones reducidas permite reducir el tamaño del prototipo de prótesis robótica y el Arduino DUE por su mayor capacidad de procesamiento y mayor número de pines, a continuación se detalla las características de las tarjetas de acondicionamiento mencionadas.

#### 1.1.6.1. Arduino Pro-Mini.

Es una tarjeta pequeña perteneciente a la familia ARDUINO basada en el ATmega 328, posee 14 pines digitales (entrada/salida) y 6 entradas analógicas. Es ideal para realizar proyectos donde el tamaño del prototipo es una limitante. No posee conectores, por lo que se puede soldar en la orientación que se requiera tan como se aprecia en la Figura 1.6(a). Posee memoria flash de 32KB, SRAM de 2KB y clk de 8MHz. Para su programación se requiere de un FTDI Basic Breakout [50], la cual se conecta directamente en los pines GND y BLK [51]

#### 1.1.6.2. Arduino DUE.

En la Figura 1.6(b) se contempla una tarjeta basada en un microcontrolador Atmel SAM3X8E que tiene un procesador ARM Cortex-M3 de 32 bits. Tiene un total de 54 entradas y salidas (12 pueden ser utilizadas como salidas PWM), 12 como entradas analógicas, 4 UARTs, un reloj de 84MHz, memoria flash de 512KB, SRAM de 96KB, conexión USB-OTG, 2 DAC. 2 TWI, un conector JTAG, un botón de reset y un botón de borrar [52].

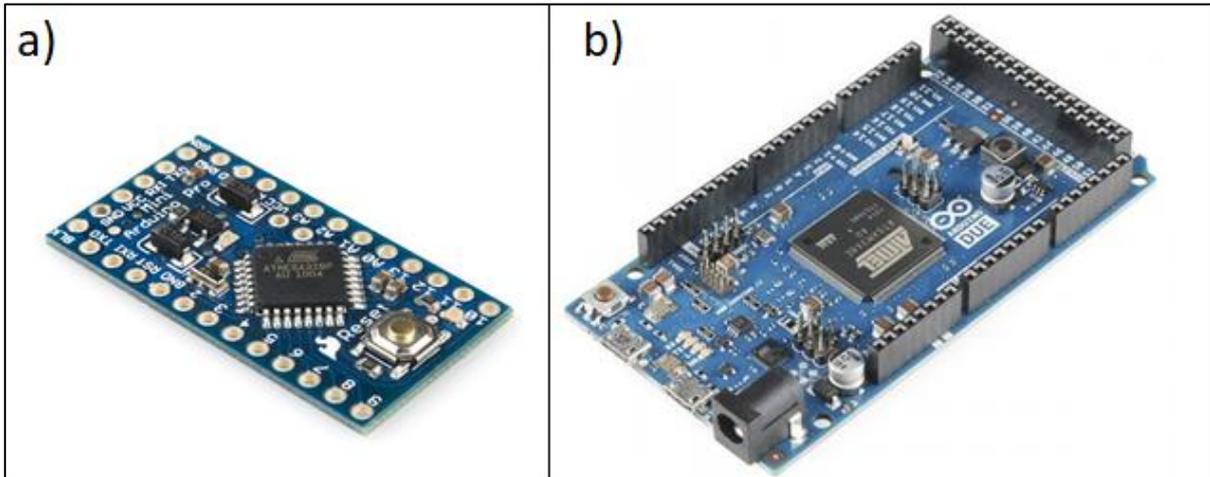


Figura 1.6 a) Arduino Pro Mini; b) Arduino DUE  
Fuente: [51], [52].  
Elaboración: Autores

### 1.1.7. Prototipo de Prótesis.

El desarrollo del sistema de control de agarre de la prótesis robótica, junto al proceso de diseño del sistema de control y diseño de PID se lo puede estudiar de forma más detallada en [20].

## 1.2. Arquitectura del Software.

En la Figura 1.7 se muestra la arquitectura del software del sistema de reconocimiento de patrones. Consta de dos fases: fase de aprendizaje del sistema y la fase de identificación de patrones. La primera fase consta de 4 módulos independientes de los módulos de la segunda fase. El módulo de la RNA embebida depende del resultado del entrenamiento de la red. Posteriormente se explicará cada módulo y como este afecta al sistema.

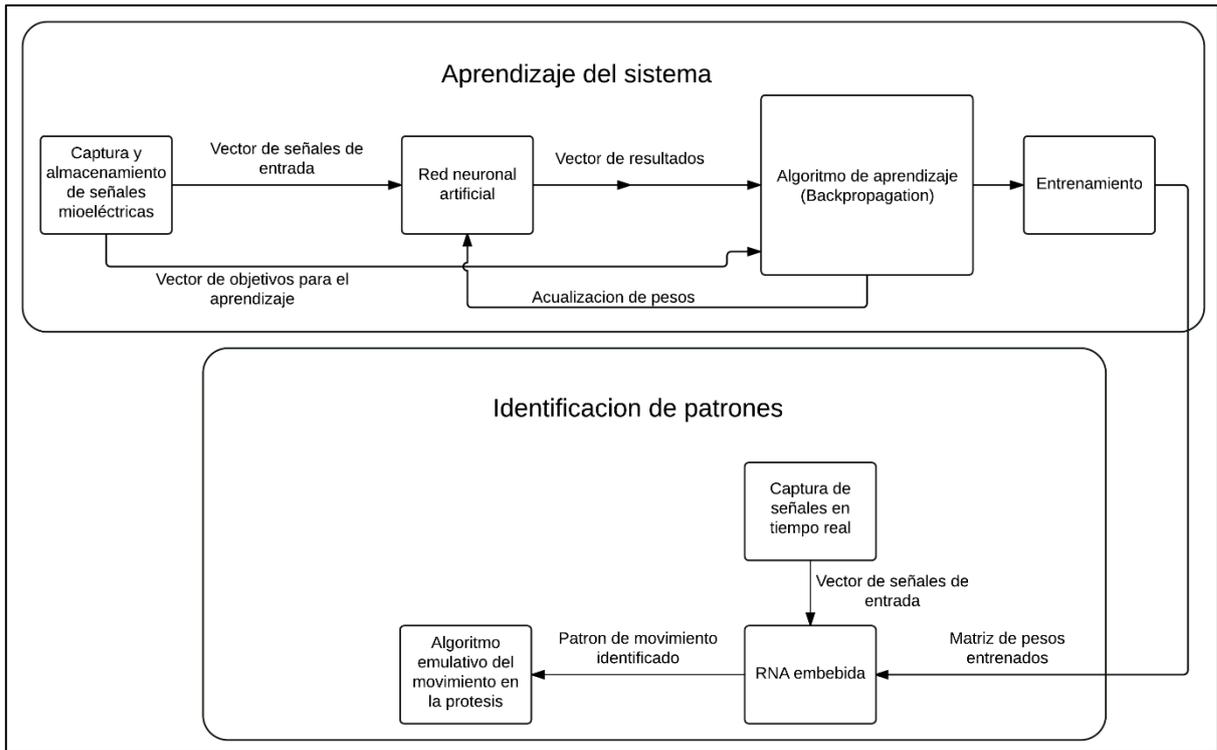


Figura 1.7 Arquitectura software del sistema de reconocimiento de patrones

Fuente: Autores

Elaboración: Autores

### 1.2.1. Captura y almacenamiento de señales mioeléctricas(EMG).

Las señales captadas por los electrodos son almacenadas en un vector y posteriormente en una matriz de entradas para el entrenamiento y prueba del sistema. Es importante el número de muestras y tiempo de muestreo ya que de ellos dependerá la velocidad de aprendizaje de la red neuronal. Las señales EMG que son capturadas por los electrodos son re-escaladas a un rango diferente de tal manera que se facilite diferenciación de valores mínimos y máximos. Los datos almacenados en la matriz de señales de entrada se dividirán en dos grupos. El primer grupo contiene los datos de entrenamiento que son usados en la fase de entrenamiento de la RNA y el segundo grupo contiene los datos de prueba que son usados para la validar el entrenamiento y calcular la precisión de la RNA.

### 1.2.2. Red neuronal artificial.

#### 1.2.2.1. Neurona Artificial.

Una neurona está constituida biológicamente por 3 componentes principales (ver Figura 1.8): las dendritas, el cuerpo de la célula y el axón. Las dendritas son receptores que llevan las señales eléctricas al cuerpo de la célula. El cuerpo de la célula suma y umbraliza las

señales entrantes. El axón se encarga de enviar la señal a otras neuronas [53]. Las redes neuronales artificiales están inspiradas en las características y estructuras de las redes neuronales biológicas. Las RNA se compone por unidades llamadas neuronas conectadas entre sí [54].

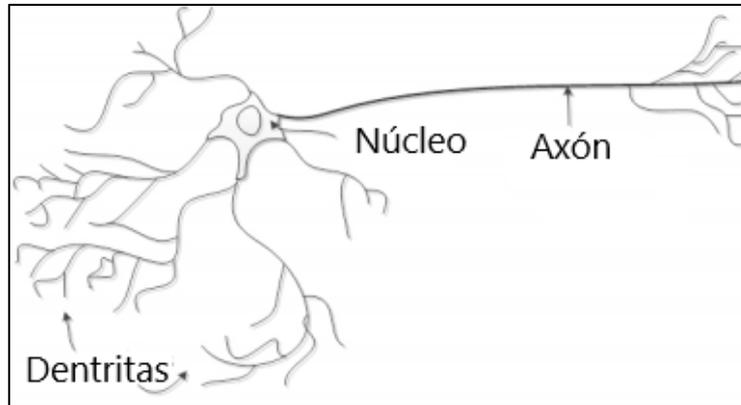


Figura 1.8 Neurona natural  
Fuente: [55]  
Elaboración: [55]

Una neurona artificial se define matemáticamente como:

$$a = f((p * w) + b) \tag{1.1}$$

Donde  $a$  es la salida de la neurona,  $a$  es el resultado de la función de transferencia o función de activación denominada  $f$  que tienen como parámetros  $w$ ,  $p$  y  $b$  ver Figura 1.9 donde  $w$  y  $b$  son parámetros escalares ajustables y únicos de cada neurona que son ajustado por las reglas de aprendizaje para satisfacer los criterios de error. El parámetro  $p$  es la información que recibe cada neurona como entrada [53].

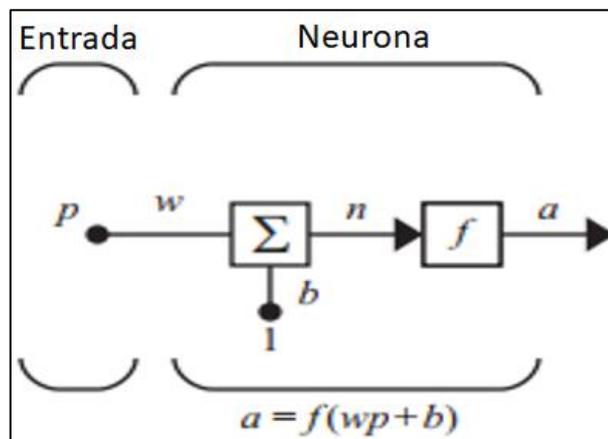


Figura 1.9 Parámetros de una neurona artificial  
Fuente: [53]  
Elaboración: [53]

La función de transferencia agrega la no linealidad al procesamiento de las redes neuronales, es necesario porque una neurona natural tiene comportamientos no lineales. Una función de transferencia generalmente está limitada entre dos valores en la salida, por lo tanto, es una función no lineal, pero en algunos casos, puede ser una función lineal [55].

Las funciones de transferencia más usadas son: (ver Figura 1.10):

- Función sigmoide
- Función tangencial
- Función lineal
- Función umbral de limitación estricto

Es recomendado que las funciones de transferencia sean no lineales en las capas ocultas, particularmente si en la capa de salida la función de transferencia es lineal. De acuerdo con el álgebra lineal, si se tiene una función lineal en todas las capas es equivalente a tener solo una capa de salida, las variables adicionales introducidas por las capas serían meras combinaciones lineales de la anterior. Por lo general, las funciones de transferencia como la función hiperbólica, tangente o sigmoide se utilizan porque son derivables [55], las funciones más usadas se muestran en la Figura 1.10.

En el presente trabajo se utiliza la función sigmoide debido al bajo costo computacional de implementar esta función en un microcontrolador, la sinergia presente en redes neuronales multicapa permite obtener una precisión arbitraria en las salidas de la red y la derivabilidad [56].

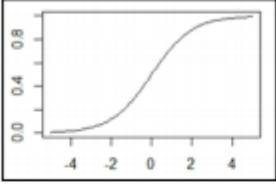
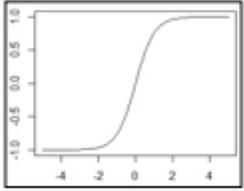
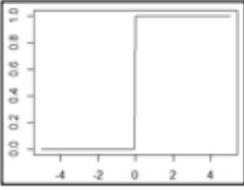
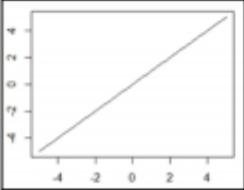
Function	Equation	Chart
Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$	
Hyperbolic tangent	$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$	
Hard limiting threshold	$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x \geq 0 \end{cases}$	
Linear	$f(x) = x$	

Figura 1.10 Funciones de transferencia más usadas

Fuente: [55]

Elaboración: [55]

### 1.2.2.2. Arquitectura de la red neuronal.

Existen 2 modalidades de arquitectura para las redes neuronales [55]:

- Según el flujo de señal
  - Feedforward: redes neuronales en las cuales el flujo de señal va únicamente hacia adelante
  - Feedback: redes neuronales en las cuales el flujo de señal va hacia adelante y hacia atrás generando una retroalimentación
- Según el número de conexiones
  - Redes monocapa: redes con una única capa oculta
  - Redes multicapa: redes con más de 2 capas ocultas

### 1.2.2.3. Feedforward.

En la arquitectura Feedforward la capa de entrada es alimentada con las señales EMG, luego de ser procesadas se envían a la siguiente capa de neuronas como se observa en la Figura 1.11, y así sucesivamente hasta llegar a capa de salida [55]. Cada una de las

neuronas en una red Feedforward tendrá el mismo tipo de ecuación como la que se muestra en la ecuación 1.2. Se eligió la arquitectura Feedforward para el diseño de la RNA debido a la simpleza de modelar matemáticamente una red neuronal feedforward.

$$a_i = f \left( \sum_0^n (a_{i-1} * w_i + b_i) \right) \quad (1.2)$$

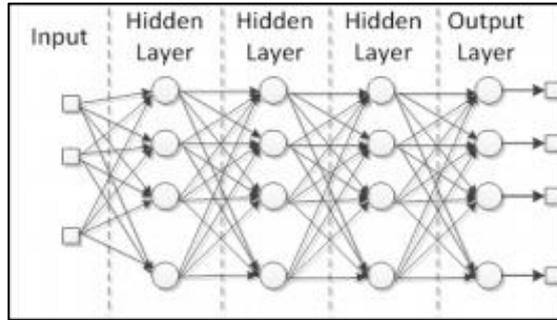


Figura 1.11 Red neuronal artificial Multicapa  
Fuente: [11]  
Elaboración: [11]

#### 1.2.2.4. Redes Multicapa

Una red con una sola capa tiene un límite de decisión que es un hiperplano como se puede observar en la Figura 1.12(a). Una red con dos capas puede generar un límite de decisión que consiste en segmentos de hiperplanos ver Figura 1.12(b). Las redes neuronales con 3 capas de pesos pueden generar regiones de decisión arbitrarias como se ve observa en la Figura 1.12(c). Por lo tanto, las redes neuronales con más capas pueden clasificar mayor número de clases, pero aumenta su complejidad y coste computacional [56].

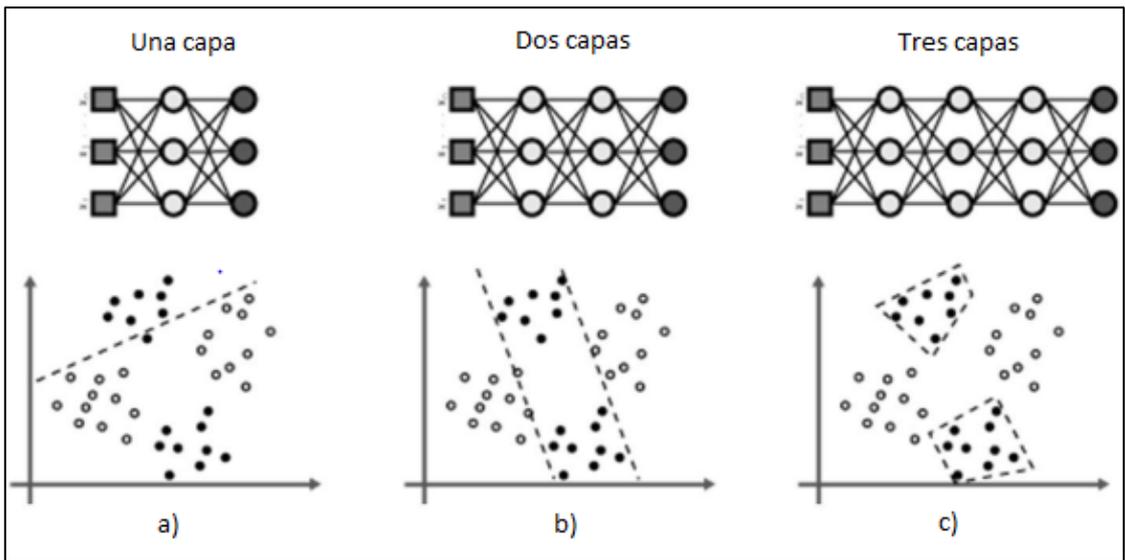


Figura 1.12 Límite de decisión de una mono red (a). Límite de decisión de una red con dos capas (b). límite de decisión arbitraria generada por una red de tres capas (c)  
 Fuente: [57]  
 Elaboración: [57]

En una red con varias capas, cada capa tiene su propia matriz de pesos o enlaces  $W$ , su propio vector bias  $b$ , una red de  $n$  entradas, y su vector de salida  $a$ . Es necesario introducir una notación para distinguir cada una de las capas. Usaremos superíndices para identificar las capas. Específicamente, en este trabajo se añadirá el número de la capa como superíndice a los nombres de cada una de estas variables. La matriz de pesos para la primera capa se escribirá  $W^1$ , para la segunda capa será  $W^2$ . Esta notación está usada en una red de 3 capas como se observa en la Figura 1.13 [53].

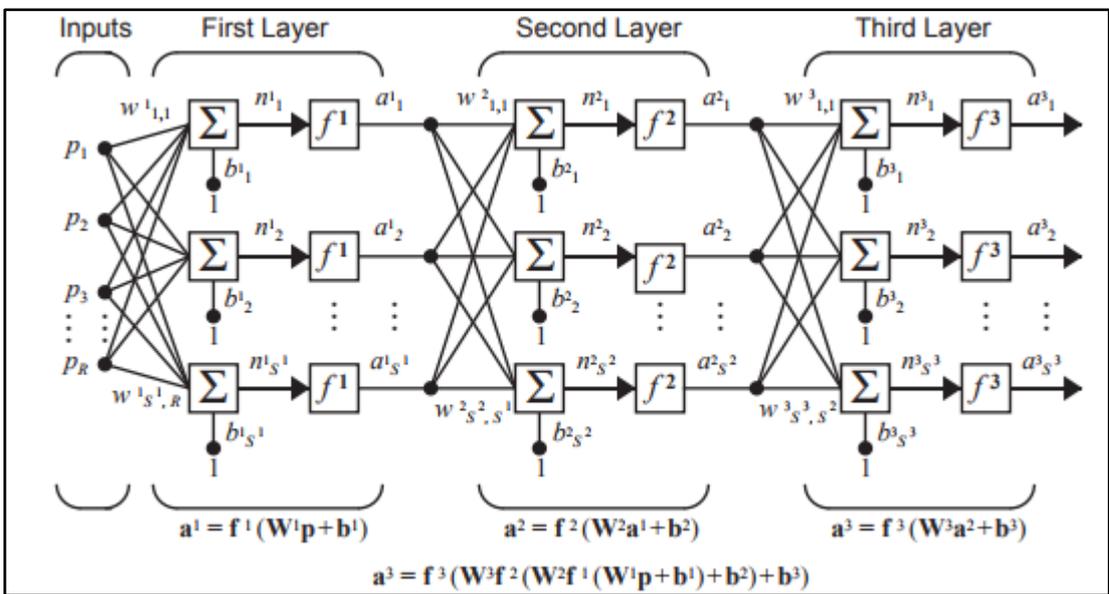


Figura 1.13 Notación de Red neuronal de 3 capas  
 Fuente: [9]  
 Elaboración: [9]

### 1.2.3. Algoritmo de aprendizaje.

El aprendizaje de las redes neuronales se realiza mediante el ajuste de las conexiones entre las neuronas (pesos). Los pesos representan el conocimiento de la red neuronal. Diferentes pesos hacen que la red produzca diferentes resultados para las mismas entradas. El esquema de aprendizaje de una red neuronal se puede observar en la Figura 1.14 [55].

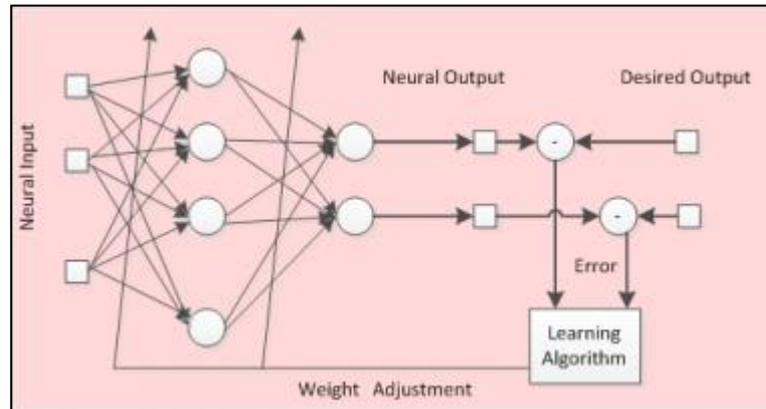


Figura 1.14 Esquema del aprendizaje de una red neuronal artificial  
Fuente: [16]  
Elaborado: [16]

El proceso representado en la figura anterior se denomina aprendizaje supervisado ya que existe un resultado deseado, pero las redes neuronales pueden aprender únicamente por los datos de entrada, si no existe un resultado deseado este aprendizaje se denomina aprendizaje no supervisado [55].

#### 1.2.3.1. Función de Error.

El objetivo central del entrenamiento de la red no es para memorizar los datos, sino más bien para modelar los datos del entrenamiento, para que las predicciones sean correctas para cualquier señal de entrada diferente a los datos de entrenamiento [56]. Los algoritmos de aprendizaje se encargan de reducir el error de las salidas, existen varias funciones de error, siendo el error cuadrático medio (MSE) la más utilizada para minimizar el error, su fórmula se presenta en la siguiente ecuación [58]:

$$MSE = \frac{1}{n} \sum_{i=0}^{n-1} (t_i - o_i)^2 \quad (1.3)$$

Donde  $n$  es el número de muestra,  $t_i$  y  $O_i$  son el objetivo deseado y la salida respectivamente para cada muestra. Existen otras funciones de error como el error RMS, el error relativo medio(MRA), error minkowski entre otros [56], [58].

### 1.2.3.2. Algoritmo Backpropagation.

El algoritmo de backpropagation es una generalización de la regla delta para el perceptrón multicapa. Los beneficios de tener capas adicionales para abstraer más datos del entorno han motivado el desarrollo de un algoritmo de entrenamiento que pueda ajustar adecuadamente los pesos de las capas ocultas. El error de la capa de salida es propagado hacia las capas anteriores actualizando los pesos usando la misma ecuación de la regla de Delta ver ecuación 1.4 [55].

$$\Delta w_i = n(t[k] - y[k])x_i[k]g'(h_i[k]) \quad (1.4)$$

La función que la regla delta quiere minimizar es el error entre la salida de la red neuronal y los valores objetivo. Los parámetros que encontrar son los pesos neuronales. Este es un algoritmo de aprendizaje mejorado en comparación con la regla del perceptrón, ya que tiene en cuenta la derivada de la función de activación o de transferencia  $g'(h)$ , que en términos matemáticos indica la dirección donde la función del error está disminuyendo más [55].

El funcionamiento del algoritmo sigue los pasos del diagrama de flujo de la Figura 1.15.

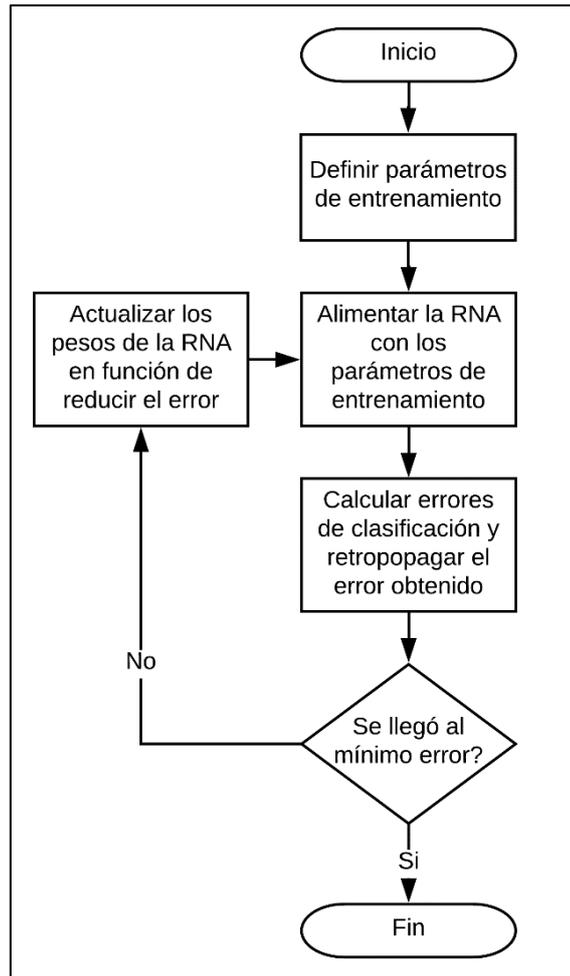


Figura 1.15 Esquema del funcionamiento del algoritmo Backpropagation  
 Fuente:[16]  
 Elaboración: Autores

#### 1.2.4. Entrenamiento.

El proceso de entrenamiento de una red neuronal empieza inicializando los pesos en valores pequeños distintos de cero. Generalmente estos valores son generados aleatoriamente. Una señal de los datos de entrenamiento es enviada a la red, se calcula el error de la RNA comparando la salida de la red con los valores deseados. Se ejecuta el algoritmo de aprendizaje el cual hace que los pesos de la red se actualicen de tal manera que el error se minimice. Este ciclo de procesos se denomina época y se repite cuantas veces sea necesario, como se observa en la Figura 1.16 conforme aumenta el número de épocas se reduce la diferencia entre el error actual y el anterior, cabe mencionar que no se puede tener un número de épocas muy elevado ya que en algún punto deja de ser útil y la función de aprendizaje se vuelve ineficaz. A menudo, todo el conjunto de entrenamiento se usa para

una época. Si se utilizan subconjuntos, es importante que sean elegidos al azar, o el aprendizaje puede verse afectado [58].

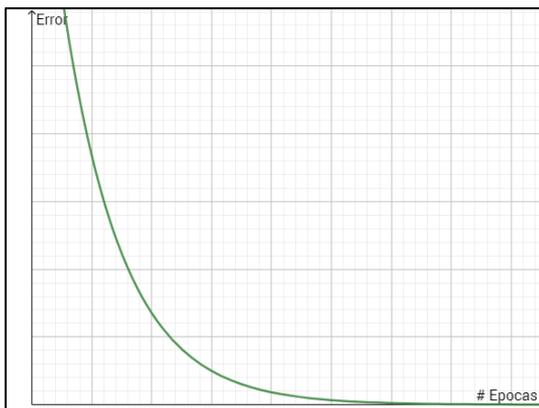


Figura 1.16 Error en función del número de épocas

Fuente: Autores

Elaboración: Autores

## **CAPÍTULO 2**

### **DISEÑO DEL SISTEMA DE RECONOCIMIENTO DE PATRONES**

En el presente capítulo se explica el diseño del sistema de identificación de patrones dividido en 4 módulos. En el primer módulo se detalla el control de las señales EMG como señales de entrada, en el segundo módulo se encuentra el diseño de la RNA y las funciones secundarias que intervienen en ella, en el tercer módulo se explica el diseño de la función de aprendizaje, y en el cuarto modulo se detalla cómo se diseñó el proceso de entrenamiento de la RNA.

## 2.1. Diseño del sistema de reconocimiento de patrones.

### 2.1.1. Captura y almacenamiento de señales EMG.

Las señales son capturadas con un tiempo de muestreo determinado y almacenadas en un vector de entrada de longitud  $N$ . El tiempo de entrenamiento depende de la longitud del vector de entrada, consecuentemente a mayor longitud del vector de entrada, mayor número de neuronas en la capa de entrada y en la primera capa oculta de neuronas.

### 2.1.2. Diseño de la red neuronal artificial.

El diseño de la red neuronal se ha dividido en dos funciones, en la primera función se dedica a la asignación del número de neuronas, numero de capas y la generación aleatoria de los pesos iniciales, y la segunda función es la propia red neuronal diseñada para modificarse con los parámetros variables de la primera función. La RNA se basa en una red multicapa debido a la región de precisión arbitraria que puede generar este tipo de red. La topología de la red se muestra en la Figura 2.1. Se observa que la primera capa oculta tiene  $2d$  neuronas donde  $d$  es el número de neuronas en la capa de entradas.

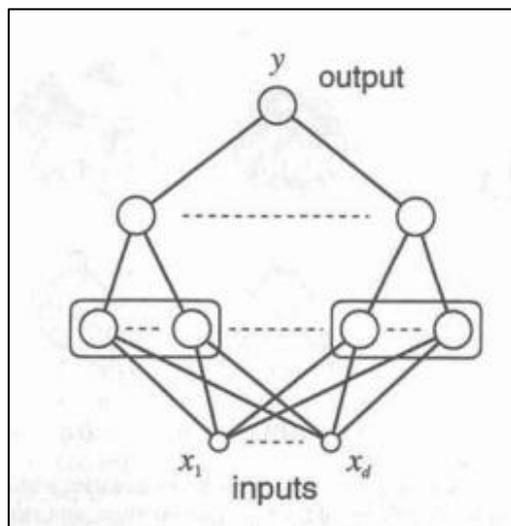


Figura 2.1 Topología de Red neuronal multicapa

Fuente: [56]

Elaboración: [56]

La función de transferencia utilizada en este trabajo es la función sigmoide, ya que el cálculo de su derivada es simple, reduciendo el coste computacional y el tiempo de ejecución de la red considerando que en la salida del sistema no se requiere un amplio rango de valores. Las entradas son re-escaladas a valores entre -2 y 2 para mejorar la precisión de la respuesta de la función de transferencia de las neuronas de la capa de entrada, con esto se reducen las respuestas ambiguas que se generan al tener valores de 0 hacia adelante. Como se puede observar en la Figura 2.2 los cambios de respuesta de la función de transferencia sigmoide se dan entre los valores de -2 y 2. Al usar la función sigmoide en una red de 3 capas ocultas aumenta la capacidad de separabilidad de clases de la red, es decir puede distinguir con precisión arbitraria entre las diferentes clases, cabe recalcar que esto se debe principalmente al número de capas ocultas. Como se muestra en las ecuaciones 2.1 y 2.2 la función sigmoide y su derivada son sencillas de determinar.

$$f(x) = \frac{1}{1 + 10^{-x}} \quad (2.1)$$

$$f'(x) = f(x)(1 - f(x)) \quad (2.2)$$

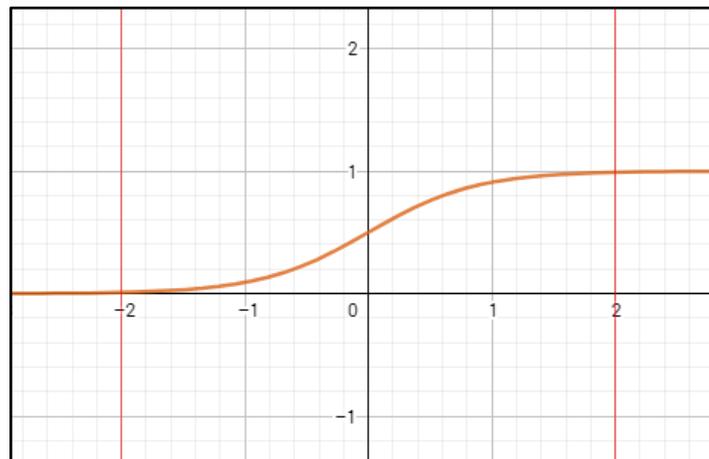


Figura 2.2 Función de transferencia sigmoide  
Fuente: Autores  
Elaboración: Autores

El flujograma de la Figura 2.3 indica de forma simplificada el funcionamiento de la red. La finalidad de la red es generar una matriz de salidas que corresponden a cada capa de neuronas que serán utilizadas por el algoritmo de backpropagation.

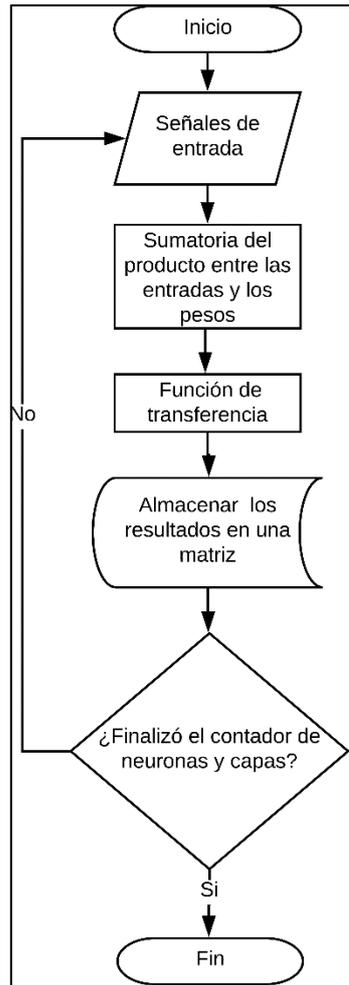


Figura 2.3 Esquema de la RNA implementada.  
 Fuente: Autores  
 Elaboración: Autores

### 2.1.3. Aprendizaje del sistema.

#### 2.1.3.1. Algoritmo de Backpropagation.

Siguiendo el diagrama de la Figura 2.4, se ejecuta la red neuronal y se calcula el MSE del resultado de la red comparándolo con el resultado deseado, después se calcula la variación delta de la capa de salida, con el delta obtenido en la capa de salida, se calcula el delta de la capa anterior y se realiza este proceso hasta llegar a la primera capa oculta conforme a las ecuaciones 2.3 y 2.4. Luego de obtener las variaciones delta se puede realizar la actualización de los pesos, estas actualizaciones deberán ser en la dirección para la cual la función de error se minimiza, como se muestra en la Figura 2.5, el error se minimiza para un peso de valor D.

$$\delta_j = f'(RED_j)(t_j - O_j) \quad (2.3)$$

$$\delta_h = f'(RED_h)(\delta_j * W_{jh}) \quad (2.4)$$

$\delta_j$  es la variación delta de las salidas respecto a los resultados deseados y  $\delta_h$  son las variaciones delta de las capas anteriores a la capa de salida donde  $f'(RED_j)$  es la derivada de la capa de salida,  $f'(RED_h)$  es la derivada de las capas anteriores a la capa de salida,  $t_j$  y  $O_j$  son los resultados deseados y las salidas, respectivamente.

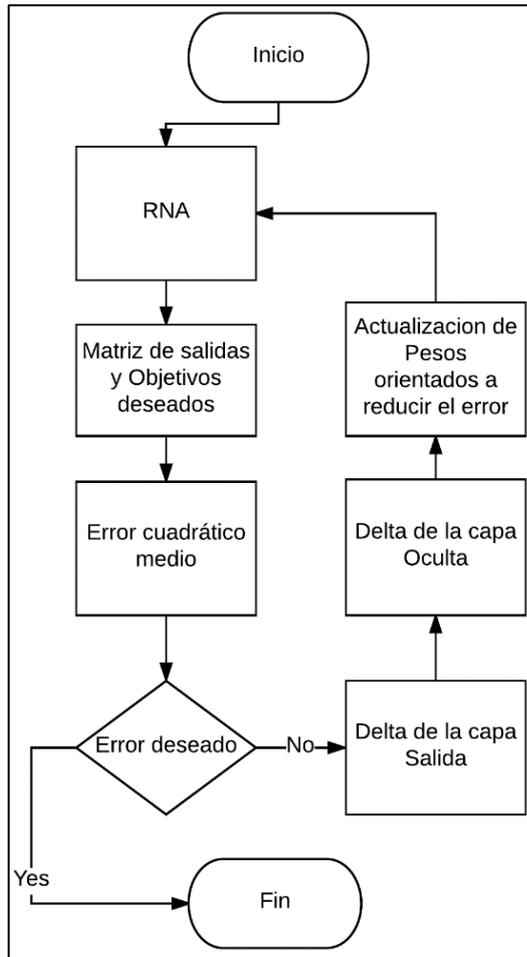


Figura 2.4 Diagrama del algoritmo de Backpropagation  
 Fuente: [58] Fuente: [58]  
 Elaboración: Autores

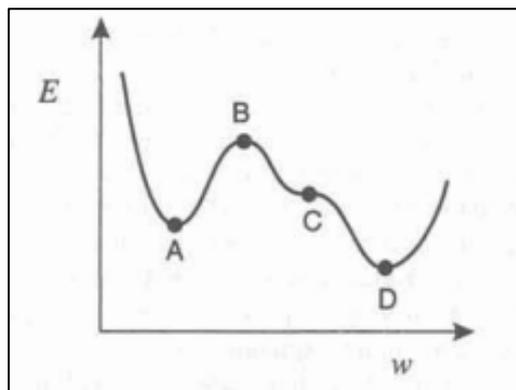


Figura 2.5 Error en función de los pesos de la red neuronal  
 Fuente: [56]  
 Elaboración: [56]

#### 2.1.4. Entrenamiento.

La fase entrenamiento tiene como objetivo conseguir un error que satisfaga los requerimientos planteados para el sistema, las funciones principales del entrenamiento son la RNA, el algoritmo de aprendizaje y el cálculo del error, en la siguiente figura se observa el diagrama de la fase de entrenamiento.

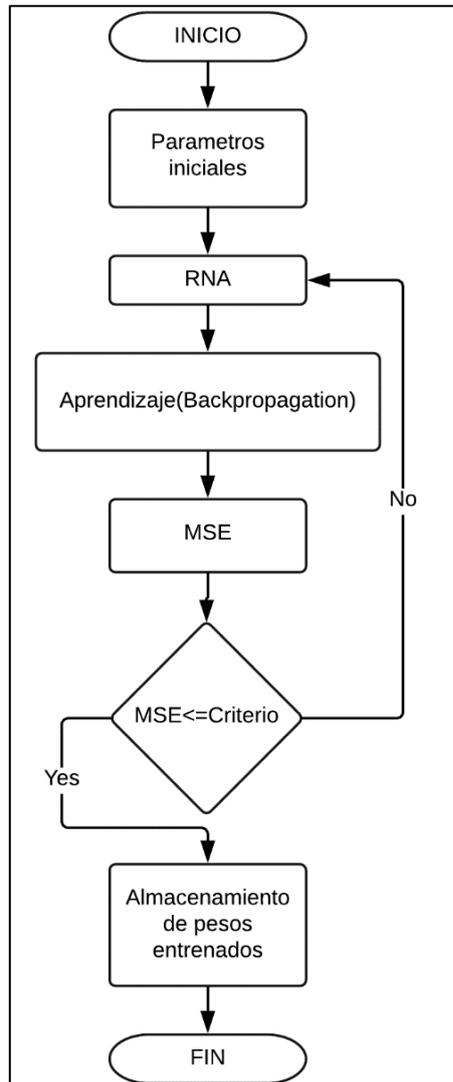


Figura 2.6 Diagrama del entrenamiento

Fuente: Autores

Elaboración: Autores

Como se puede observar en la Figura 2.6, primero se establece el número de neuronas, número de capas y pesos iniciales, que son parámetros necesarios para la RNA. El entrenamiento del sistema se diseñó como una función que ejecuta a la red neuronal, el algoritmo de aprendizaje y la función de error como subfunciones dentro de un mismo ciclo de ejecución. Como se mencionó en el apartado 1.2.4 este ciclo de procesos es denominado época de aprendizaje, y se repite cuantas veces sea necesario para reducir el

error cuadrático medio, creando así un bucle con un número máximo de ciclos. Cuando el error sea el deseado se concluye el entrenamiento mediante una interrupción del bucle y se almacena los pesos entrenados. Los pesos entrenados son almacenados en la memoria del microcontrolador para ser utilizados por la RNA embebida.

**CAPÍTULO 3**  
**IMPLEMENTACIÓN DE LOS SISTEMAS DE ADQUISICIÓN DE SEÑALES EMG Y**  
**RECONOCIMIENTO DE PATRONES**

### 3.1. 3Implementación del Sistema de sistemas de adquisición de señales EMG.

#### 3.1.1. Tarjeta de acondicionamiento.

A continuación, se detalla el proceso para la selección de la tarjeta de acondicionamiento:

- Se evaluó los sensores Muscle Sensor V3, Grove EMG, y Surface EMG Sensor SX230 los mismos que utilizan cables de un metro de longitud para la conexión de los electrodos a través de un conector TRRS, Las pruebas realizadas permitieron comprobar que la distancia existente entre los electrodos y la tarjeta aumenta la distorsión de la señal por interferencias existentes en el medio, ya sea por ruido blanco o la interferencia de las líneas eléctricas (60Hz). Además, estas tarjetas de acondicionamiento hacen que el tamaño del sistema de adquisición de señales aumente y sea menos cómodo para el usuario.
- Se realizó pruebas con la tarjeta MyoWare Muscle Sensor la cual es compacta y tiene un excelente acondicionamiento, ya que amplifica, filtra, rectifica e integra la señal EMG para su posterior procesamiento. En la Figura 3.1 se puede observar una señal EMG extraída con el MyoWare Muscle Sensor junto con la tarjeta de procesamiento Arduino Pro-Mini y el software Matlab, los electrodos han sido ubicados sobre el grupo palmar del antebrazo únicamente con fines experimentales

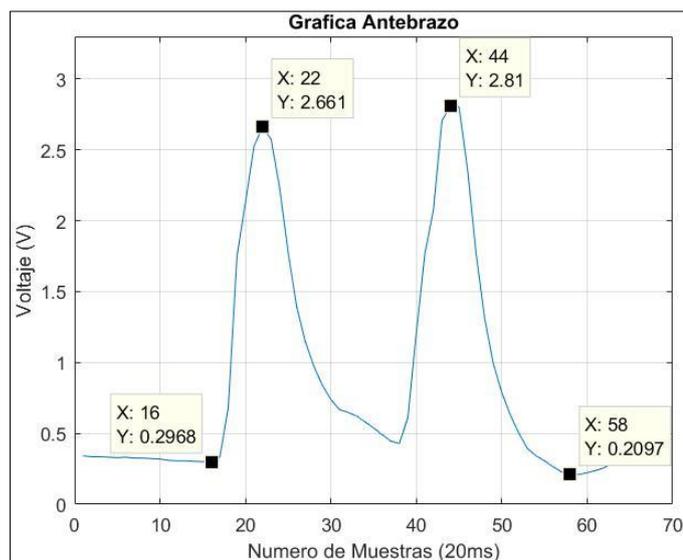


Figura 3.1 Señal EMG-MyoWare Muscle Sensor  
Fuente: Autores  
Elaboración: Autores

Se puede observar que la señal EMG extraída posee una excelente relación señal-ruido y con un nivel de amplitud aceptable para poder ser detectado como una contracción del músculo, sabiendo que 3.3 voltios el voltaje máximo del ADC.

### 3.1.2. Selección de Electroodos.

En la selección del tipo de electrodo a utilizar se consideró algunas características importantes como el tiempo de vida, características de conductividad y comodidad para el usuario. Se lo llevó a cabo de la siguiente manera:

- En primera instancia se pretendió utilizar electrodos de alambre fino como el descrito en la sección 1.1.3.1 por su exactitud en la medición de señales EMG, pero dada su aplicación resultó ser molesto para el usuario, ya que es invasivo para él y puede llegar a causar dolor al introducirlos. Por esta razón se optó por la utilización de electrodos de superficie descritos en la sección 1.1.3.2, los cuales son electrodos no invasivos que se colocan sobre la piel, son estables y lo más importante que son recomendados por la SENIAM ya que no producen molestias al colocar [43].
- El primer tipo de electrodo que se evaluó fue el electrodo de gel superficial H124SG Coviden (ver Figura 3.2) cuyo diámetro es de 24mm con un área adhesiva y un área con hidrogel conductivo (todas las características se las puede encontrar en [59]).



Figura 3.2 ElectrodoH124SG Coviden  
Fuente: [59].  
Elaboración: Autores

Al realizar las mediciones se obtuvo un comportamiento aceptable en la colocación y extracción de señales EMG, pero se comprobó que el tiempo de vida del electrodo era demasiado corta, ya que, al colocar y retirar el electrodo, este pierde sus propiedades de adherencia, generando fallos en la medición.

- Se elaboró otro mecanismo para la extracción de señales EMG. Las opciones consideradas fueron la elaboración de electrodos utilizando tela conductiva y electrodos de cobre.
  - La tela conductiva es un material fácil de utilizar y de bajo costo, que permite la fabricación de electrodos reutilizables para detectar la actividad muscular. Para la elaboración de este prototipo se hizo uso de la guía “Conductive Fabric Electrodes” [60], en la cual explica paso a paso como realizar su

confección. El resultado de su confección se lo puede observar en la Figura 3.3



Figura 3.3 Elaboración de electrodos a base de tela conductiva  
Fuente: [60]  
Elaboración: Autores

Una vez confeccionados se procedió a evaluar su desempeño, el mismo que no fue satisfactorio ya que no existía suficiente ajuste entre la piel y los electrodos de tela, provocando errores en la detección de la señal.

- Posteriormente, se recurrió a la elaboración de electrodos secos de cobre (Figura 3.4). Se eligió el cobre ya que se caracteriza por ser uno de los mejores conductores y gracias a su conductividad, ductilidad y maleabilidad se ha convertido en el material más utilizado para crear componentes eléctricos y electrónicos.



Figura 3.4 Electrodos de Cobre  
Fuente: Autores  
Elaboración: Autores

Con los electrodos de cobre confeccionados, se procedió a la creación de un mecanismo (armazón) para la sujeción de la tarjeta de acondicionamiento junto con los electrodos ya que, a diferencia de los electrodos de gel, estos no poseen un área adhesiva.

Este nuevo mecanismo consistió en elaborar una prótesis (armazón) de polimetilmetacrilato (PMMA) que se acople al antebrazo.

- Primero se procedió a diseñar un molde de yeso para la prótesis en el antebrazo de uno de los autores (Figura 3.5(a)).

- Con la ayuda de un horno de luz infrarroja (Figura 3.5(b)), se procedió a calentar las láminas de PMMA hasta que se volvió transparente y maleable, para ser colocado sobre el molde de yeso.
- Con la ayuda de una máquina compresora se fusionó el yeso y la lámina de PMMA (Figura 3.5(c)).
- Una vez fusionados los dos materiales se probó en el antebrazo (Figura 3.5(d))

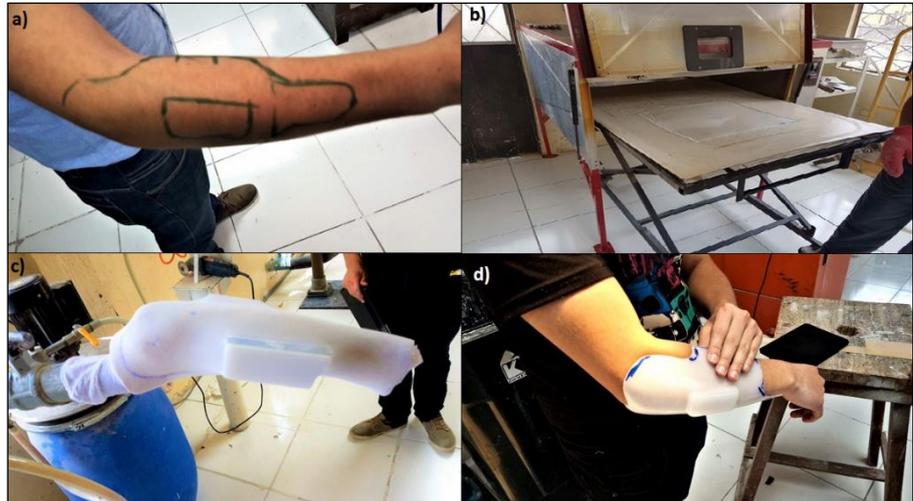


Figura 3.5 a) Diseño de prótesis para creación de molde de yeso. b) Horno de luz infrarroja y lámina de PMMA. c) fusión de molde de yeso con la lámina de PMMA. d) Prueba de prótesis de PMMA

Fuente: Autores

Elaboración: Autores

Se realizaron pruebas con los electrodos de cobre a 3 personas elegidas al azar y se obtuvo las señales EMG con una relación señal-ruido y niveles de señal aceptables para poder identificar los movimientos realizados. Pero para que exista buen contacto entre el electrodo y la piel se requería ejercer suficiente presión sobre el armazón. Al permanecer la presión ejercida con el armazón y los electrodos sobre la piel de forma prolongada, esta crea úlceras por presión en la piel. La ulcera producida causa dolor y picazón a los pacientes.

Realizadas las pruebas con todos los electrodos especificados anteriormente, para este proyecto se ha elegido los electrodos de gel por su facilidad de colocación y excelentes características en la extracción de señales EMG.

### 3.1.3. Posicionamiento de los electrodos.

Para el correcto posicionamiento de los electrodos se realizó un estudio de la anatomía del antebrazo para comprender su estructura y funcionamiento. Posterior a esto se determinó

dos enfoques, el primero fue analizar la señal EMG obtenida al ubicar los electrodos sobre los nervios que atraviesan la región del antebrazo, y el segundo fue analizar la señal EMG que se obtiene al colocar los electrodos sobre los grupos musculares que se encuentran en el antebrazo. Para la extracción de la señal se utilizó el software Matlab junto con el MyoWare Muscle Sensor con electrodos de gel. Las pruebas se las realizó en el laboratorio de prototipos de electrónica y robótica de la UTPL con la ayuda de un profesional en medicina, para la identificación de los músculos de mayor importancia tanto para una óptima ubicación de los sensores como la comodidad del usuario.

La señal EMG extraída se las realizó tomando una muestra cada 20ms, se eligió este tiempo de muestreo porque es el tiempo que demora el software MATLAB para el procesamiento de la información y así poder apreciar cada evento en tiempo real.

### 3.1.3.1. Posicionamiento basado en nervios del antebrazo.

Para esta etapa se dividió el antebrazo en tres secciones con la finalidad de encontrar la mejor posición. Estas secciones fueron el tercio proximal, tercio medio y tercio distal como se puede apreciar en la Figura 3.6.

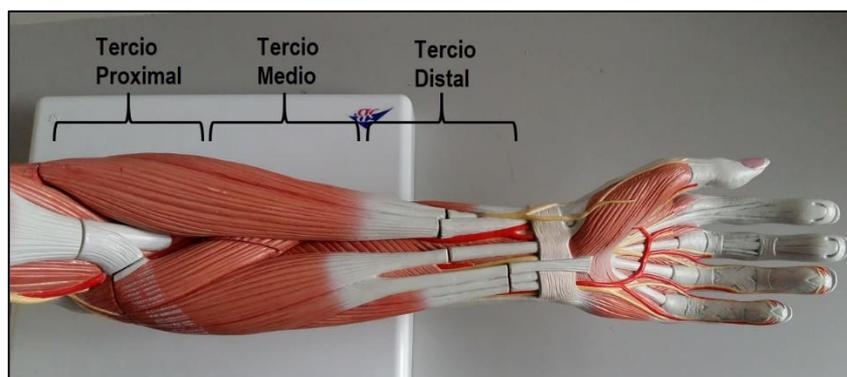


Figura 3.6 División del antebrazo  
Fuente: Autores  
Elaboración: Autores

En la Figura 3.7-a se aprecia la colocación de los sensores en la sección del tercio proximal del antebrazo, en la Figura 3.7-b se observa los sensores dispuestos en el tercio medio y en la Figura 3.7-c los electrodos se encuentran colocados en el tercio distal del antebrazo sobre los nervios: radial, cubital y medial (medio).

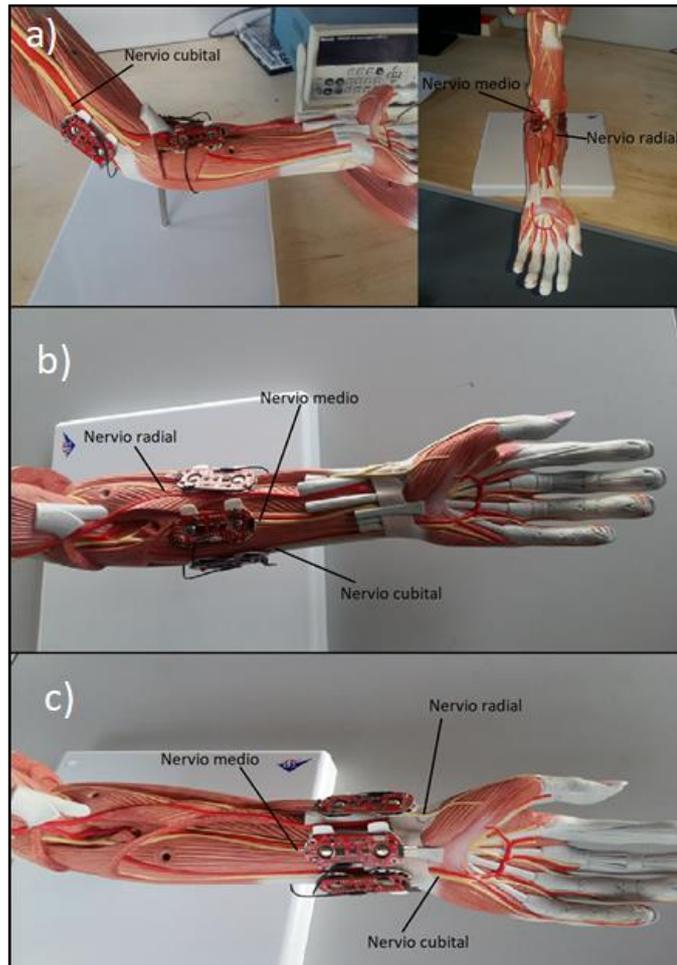


Figura 3.7 Disposición de electrodos sobre los nervios del antebrazo  
 Fuente: Autores  
 Elaboración: Autores

Los movimientos realizados para accionar cada sección del antebrazo y para cada nervio, se detalla en la Tabla 3.1.

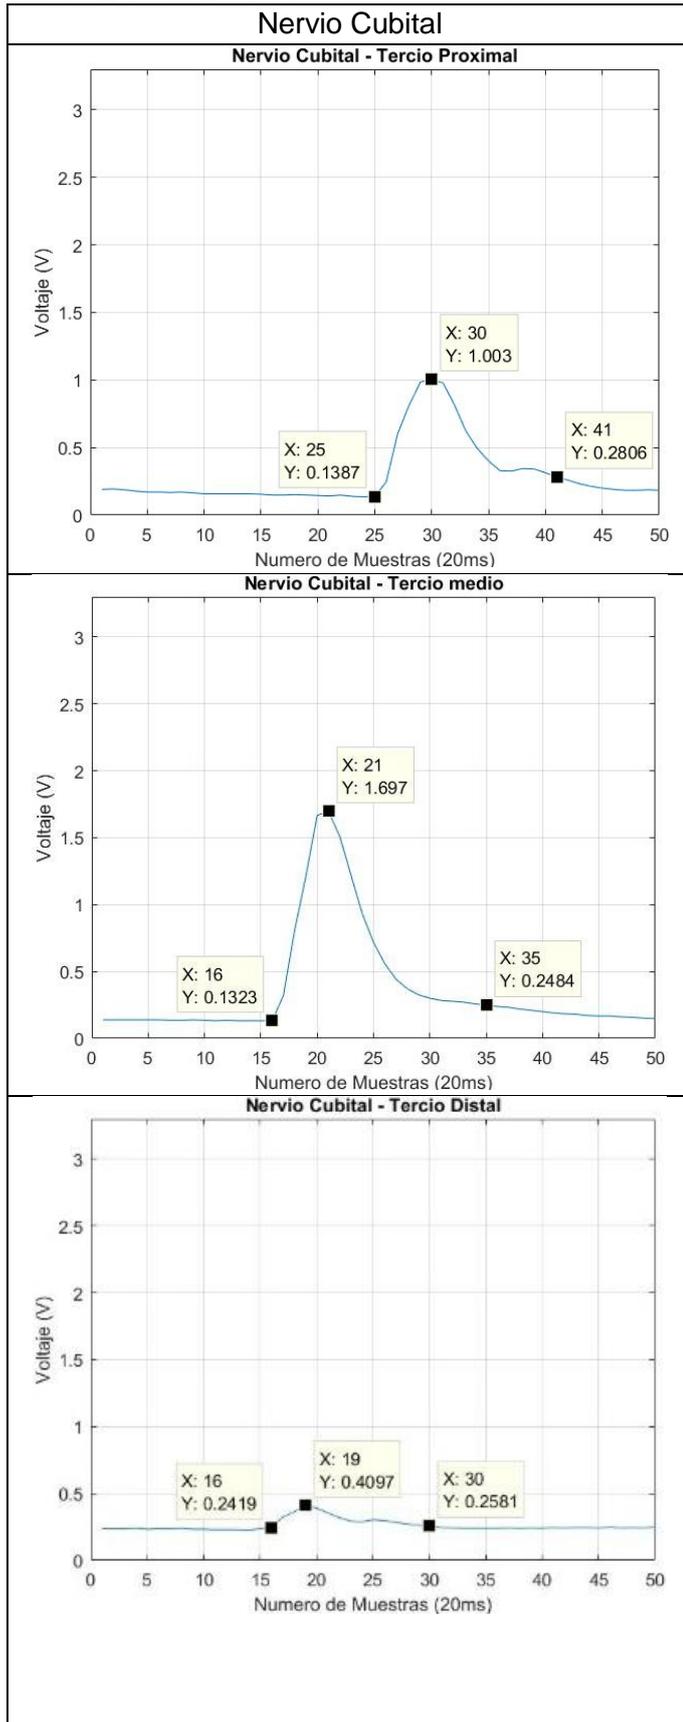
Tabla 3.1 Movimientos realizados para la acción de cara nervio

	Tercio proximal	Tercio medio	Tercio distal
Nervio Cubital	Flexión	Desv. Cubital	Meñique
Nervio Medio	Extensión	Flexión	Dedos 2°, 3° y 4°
Nervio Radial	Pronación	Supinación	Pulgar

Fuente: Autores  
 Elaboración: Autores

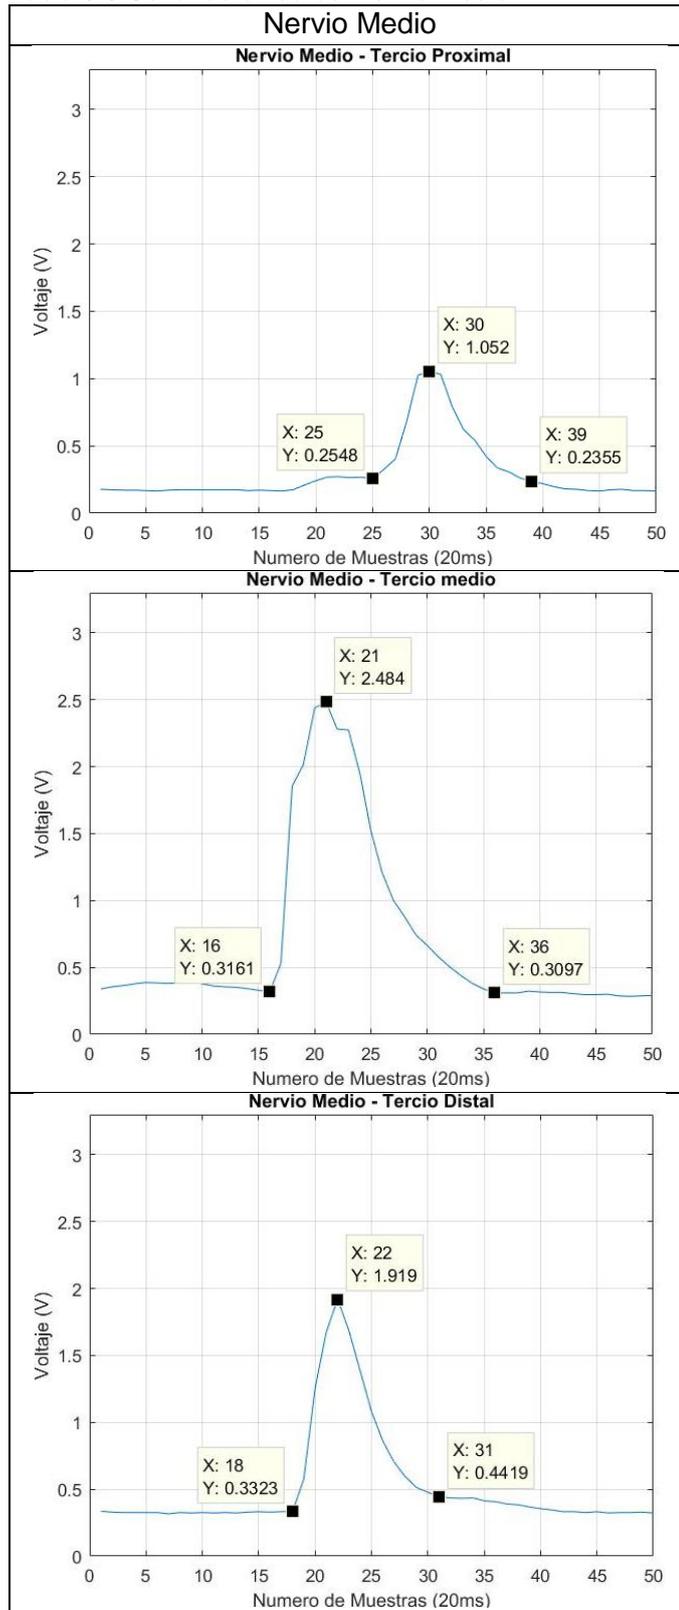
En la Tabla 3.2, Tabla 3.3 y Tabla 3.4 se observa las señales EMG del tercio proximal, medio y distal respectivamente, realizando los movimientos detallados en la Tabla 3.1.

Tabla 3.2 Señal EMG obtenida del nervio cubital



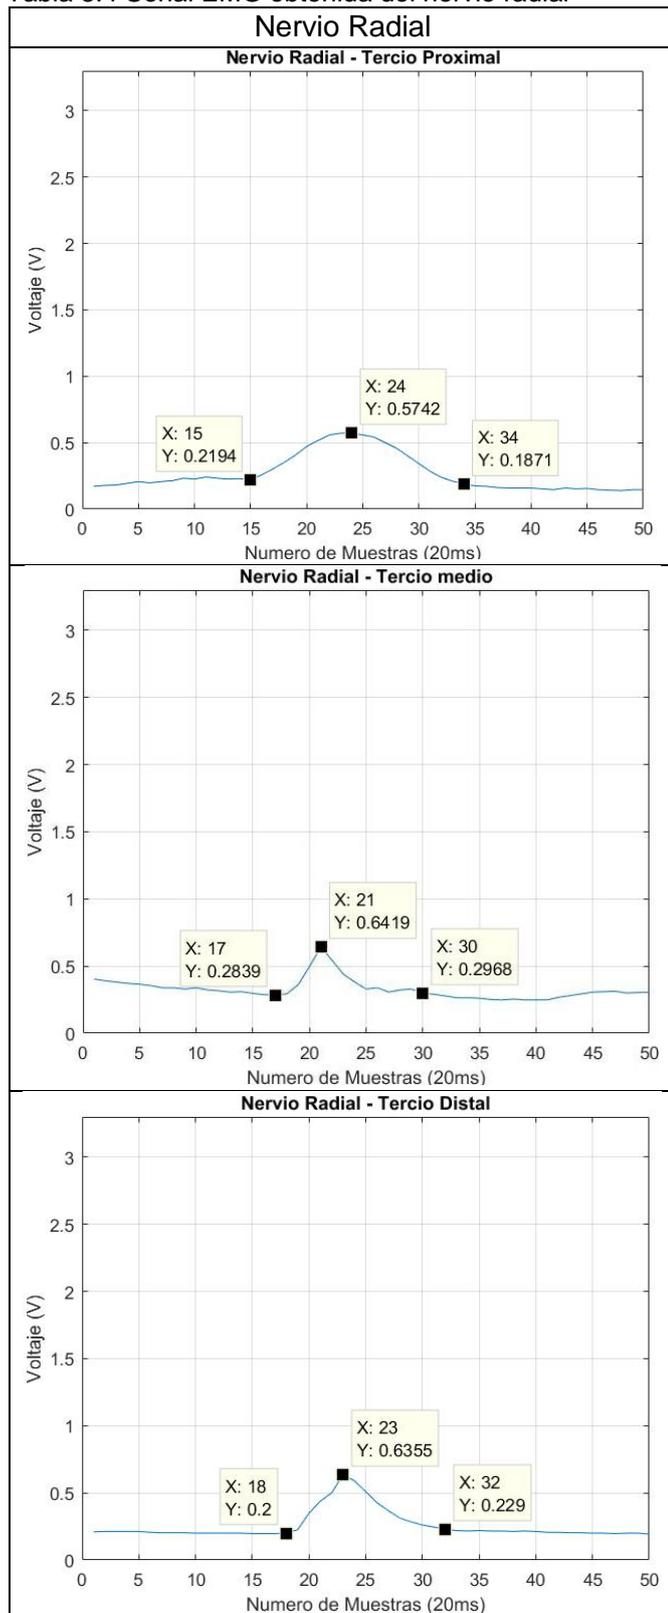
Fuente: Autores  
 Elaboración: Autores

Tabla 3.3 Señal obtenida del nervio medio



Fuente: Autores  
 Elaboración: Autores

Tabla 3.4 Señal EMG obtenida del nervio radial



Fuente: Autores  
 Elaboración: Autores

### 3.1.3.2. Posicionamiento basado en grupos musculares.

Los movimientos realizados para la extracción de las señales mioeléctricas se detallan en la 3.5.

Tabla 3.5 Movimientos realizados para la acción de cada movimiento

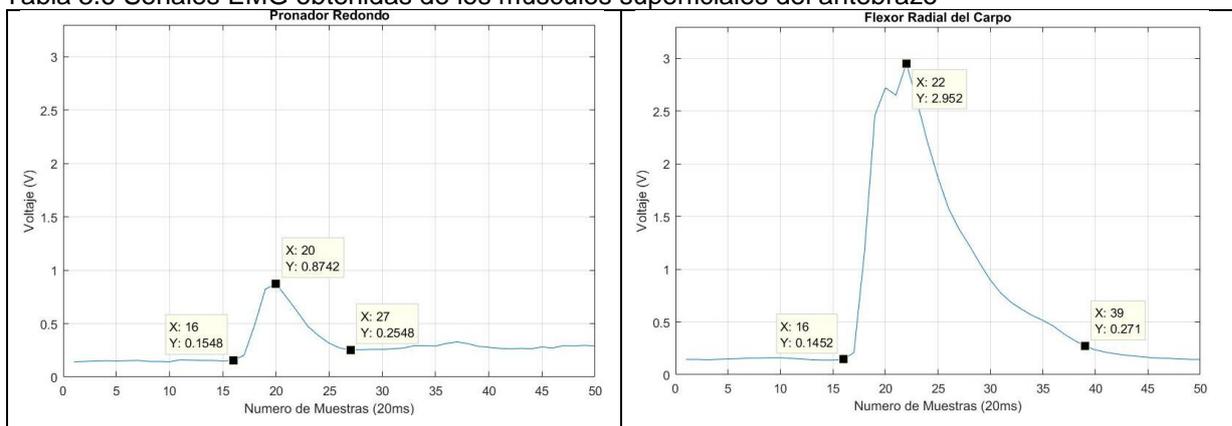
Músculo	Acción
<b>Pronador Redondo</b>	Flexión del antebrazo sobre el brazo
<b>Flexor Radial del Carpo</b>	Flexión de la muñeca
<b>Palmar Largo</b>	Flexión de la muñeca
<b>Flexor Cubital del Carpo</b>	Flexión y aducción de la muñeca
<b>Flexor Superficial de los Dedos</b>	Flexión de las falanges sobre la mano
<b>Braquiorradial</b>	Flexión del antebrazo sobre el brazo
<b>Extensor Radial Largo del Carpo</b>	Extensión y abducción de la muñeca
<b>Extensor Radial Corto del Carpo</b>	Extensión y abducción de la muñeca

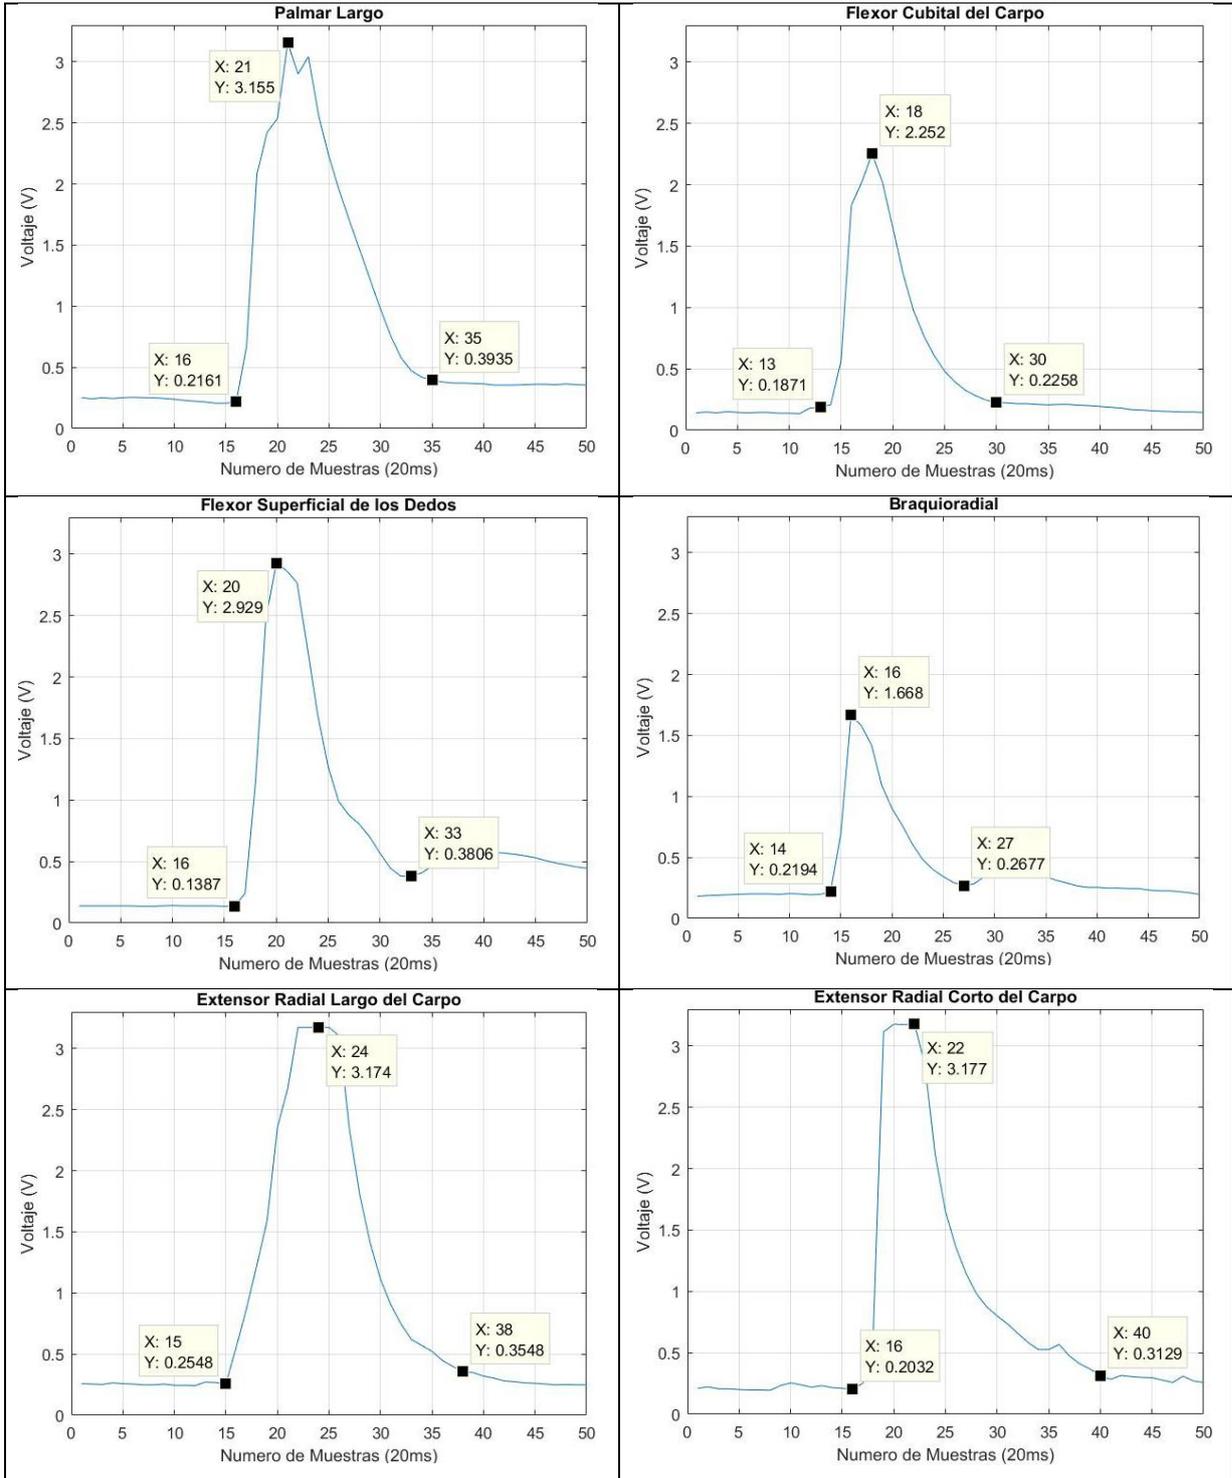
Fuente: Autores

Elaboración: Autores

Una vez detallados los movimientos necesarios para accionar cada uno de los músculos se procedió a realizar la extracción de la señal con la ayuda del software de desarrollo MATLAB. En la Tabla 3.6 se observa las señales obtenidas.

Tabla 3.6 Señales EMG obtenidas de los músculos superficiales del antebrazo





Fuente: Autores  
 Elaboración: Autores

Las características de las señales obtenidas se las puede observar en la Tabla 3.7, en esta tabla se detalla la amplitud de la señal obtenida al realizar una acción y la amplitud de la señal en reposo, que se la considera como la amplitud del ruido.

Tabla 3.7 Comparación de las señales para el posicionamiento

	Posición	A. Señal	A. Ruido	R. de amplitudes
Nervio	Cubital-Tercio Distal	0,409	0,241	1.763667671
	Cubital-Tercio Medio	1,697	0,132	12.82690854
	Cubital-Tercio Proximal	1,003	0,138	7.380073801
	Medio-Tercio Distal	1,919	0,332	5.774902197
	<b>Medio-Tercio Medio</b>	<b>2,484</b>	<b>0,316</b>	<b>8.749559704</b>
	Medio-Tercio Proximal	1,052	0,254	6.395136778
	Radial-Tercio Distal	0,635	0,2	3.284237726
	Radial-Tercio Medio	0,641	0,283	2.584138486
	Radial-Tercio Proximal	0,574	0,219	4.139870224
Músculo	Braquiorradial	1.668	0.1806	9.235880399
	<b>Extensor radial corto</b>	<b>3.177</b>	<b>0.1935</b>	<b>16.41860465</b>
	<b>Extensor radial largo</b>	<b>3.174</b>	<b>0.2419</b>	<b>13.12112443</b>
	<b>Flexor radial del carpo</b>	<b>2.929</b>	<b>0.1387</b>	<b>21.11751983</b>
	<b>Flexor superficial de los dedos</b>	<b>2.93</b>	<b>0.138</b>	<b>21.22463768</b>
	Flexor cubital del carpo	2.252	0.1355	16.6199262
	<b>Palmar largo</b>	<b>3.155</b>	<b>0.2065</b>	<b>15.27845036</b>
	Pronador redondo	0.8742	0.1419	6.160676533

Fuente: Autores

Elaboración: Autores

En base a la tabla elaborada con las características de las señales obtenidas en cada prueba, se pudo determinar las mejores regiones del antebrazo para el posicionamiento de los electrodos. En los nervios la mejor posición para ubicar los electrodos es sobre el nervio medio en la sección del tercio medio del antebrazo, mientras que en los músculos es sobre los músculos: palmar largo, flexor superficial de los dedos, flexor radial del carpo, extensor radial largo y corto del carpo, estas posiciones se encuentran sombreadas en la tabla 3.7.

Con los resultados obtenidos se puede resumir que en la región media del antebrazo es posible obtener señales EMG cercanas a 3.3V (voltaje máximo del ADC) y un nivel de señal de ruido menor a 0.2V.

Para nuestro trabajo se ha planteado utilizar el músculo flexor radial del carpo.

#### 3.1.4. Ajuste de la señal EMG.

Una vez seleccionada la mejor posición para la colocación de los electrodos, se procedió a realizar un ajuste en la señal para adaptarla a la entrada de la RNA. Este ajuste se lo realizó en lenguaje de programación C a través de una función que se la puede analizar detalladamente en el anexo A. La función está formada de dos etapas. La primera etapa consistió en la toma de una señal de prueba para extraer valores máximos y mínimos, ya que cada persona genera distintas señales EMG. La segunda etapa ajusta la señal EMG

leída a valores de +3 y -3, representando el nivel máximo y mínimo de la señal respectivamente. Para este propósito se utilizó la expresión matemática (3.1)

$$S_{EMG} = \frac{(V_{leído} - \text{mínimo}) * 20}{\text{máximo} - \text{mínimo}} - 10 \quad (3.1)$$

En donde cada variable representa:

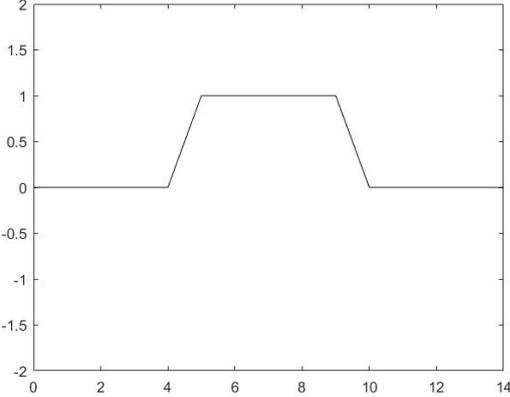
- $S_{EMG}$  : Señal EMG ajustada
- $V_{leído}$  : Señal EMG real, antes del ajuste
- $\text{mínimo}$  : Valor mínimo extraído en la primera etapa
- $\text{máximo}$  : Valor máximo extraído en la primera etapa

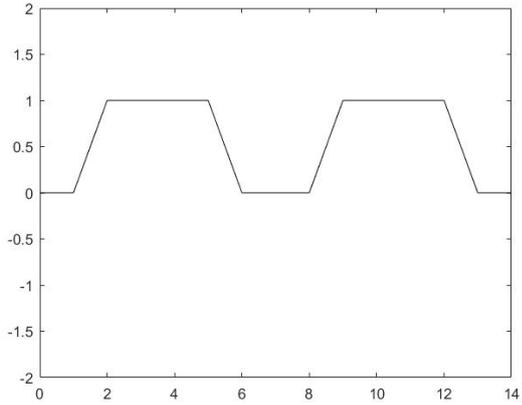
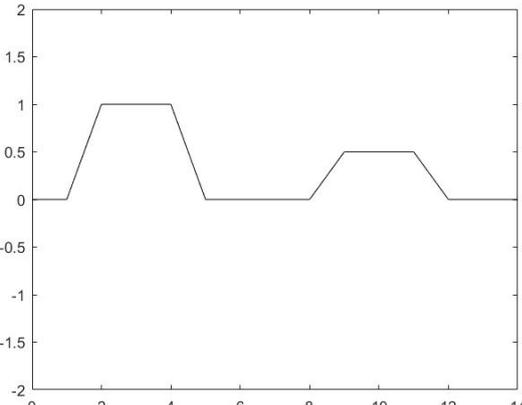
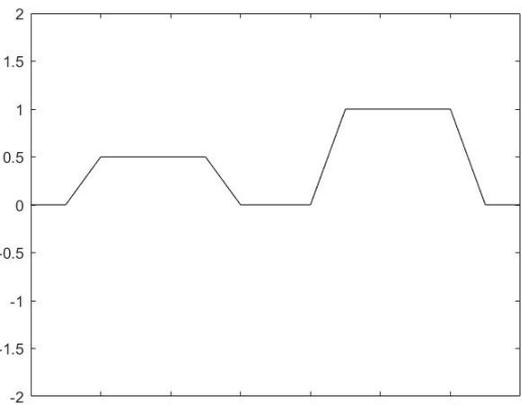
### 3.1.5. Selección de movimiento y secuencia de patrones.

Para la selección de patrones se ha considerado la facilidad que poseen las personas con amputación de miembro superior para simular ciertos movimientos de la mano. Bajo recomendaciones del personal médico de la fundación Hermano Miguel se eligió los movimientos más fáciles de realizar que son flexión y extensión de la mano. En el presente trabajo y en base a las recomendaciones mencionadas, se ha elegido utilizar el movimiento flexión de la mano para la extracción de las señales EMG.

Con la finalidad de brindar al usuario mayor comodidad en el uso de prótesis robóticas, se ha utilizado una sola tarjeta de acondicionamiento con tres electrodos, lo cual significa que solo se puede realizar la lectura de una sola señal EMG. Por esta razón se ha creado una secuencia de patrones que se detalla en la Tabla 3.8, que consiste en la combinación de contracciones fuertes y contracciones leves del músculo.

Tabla 3.8 Selección de secuencia de patrones

Nº	Patrón	Clase
1		<p>Clase 1: Contracción fuerte</p> <p>Movimiento: Agarre cilíndrico</p>

2		<p>Clase 2: Doble contracción fuerte</p> <p>Movimiento: Apuntar</p>
3		<p>Clase 3: Contracción fuerte seguido de contracción leve</p> <p>Movimiento: Pinza</p>
4		<p>Clase 4: Contracción leve seguido de contracción fuerte</p> <p>Movimiento: Dedo pulgar en aducción</p>

Fuente: Autores  
Elaboración: Autores

### 3.2. Implementación del Módulo de reconocimiento de patrones.

La implementación del módulo de reconocimiento de patrones se realizó en un computador y en un microcontrolador. El módulo implementado en el computador se utilizó para la fase de entrenamiento de la red y por la facilidad en la depuración del código. En la

implementación de la RNA en el microcontrolador fue necesario incluir 2 funciones y excluir las funciones que fueron usadas en la fase de entrenamiento, con el propósito de ahorrar recursos y reducir el tiempo de actividad del microcontrolador. Para la implementación en el computador se eligió el IDE “Codeblocks” debido a las facilidades que presenta como son: código abierto, multiplataforma y soporta múltiples compiladores, además permite la interoperabilidad con otros programas afines como son “MATLAB” y “Atmel Studio”. La implementación embebida se la realizó utilizando el IDP “Atmel Studio” para programar los microcontroladores mencionados en capítulos anteriores, se eligió este software debido a la familiarización de los autores con el IDP y facilidades que ofrece para la depuración y la extensa comunidad que trabaja con esta herramienta y los microcontroladores AVR y ARM.

### **3.2.1. Implementación del módulo de captura y almacenamiento de las señales EMG.**

Para la implementación del módulo de captura y almacenamiento se realizó una función que se observa en el anexo B, la cual calcula la ventana de tiempo necesaria para capturar las señales. Se realizaron pruebas a 4 personas de distinta edad, sexo y contextura corporal, estas pruebas consistieron en la captura de la señal EMG de un mismo movimiento con un tiempo de muestreo de 5ms. Para determinar la ventana de tiempo necesaria se sacó el promedio del tiempo que les tomó realizar el movimiento. Como se puede observar en la Tabla 3.9, los tiempos obtenidos se encuentran en el rango de 670ms a 975 y en un rango de 144 a 195 de muestras por movimiento, determinando que la ventana de tiempo de 800ms es suficiente para capturar el movimiento de un usuario de cualquier edad y condición física. La ventana de trabajo se consideró desde el cambio de la señal en reposo a la actividad hasta el cambio de la señal en actividad a reposo. Se probó el módulo de captura con 3 tiempos de muestreo distintos obteniendo distintas configuraciones de la RNA que se pueden observar en la Tabla 3.10.

Existen 3 tipos de contextura corporal que son:

- Ectomorfo: Se caracteriza por su delgadez y por la dificultad para aumentar su masa muscular (ver Figura 3.8) [61].
- Endomorfo: almacena grasa corporal con gran facilidad y posee huesos más gruesos y cintura grande (ver Figura 3.8) [61].
- Mesomorfo: presenta robustez y una figura atlética (ver Figura 3.8) [61].

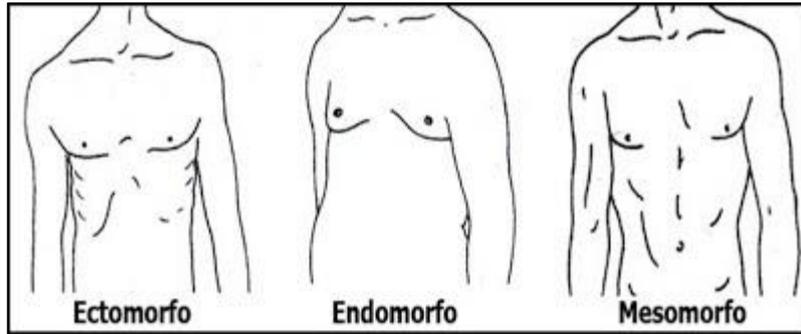
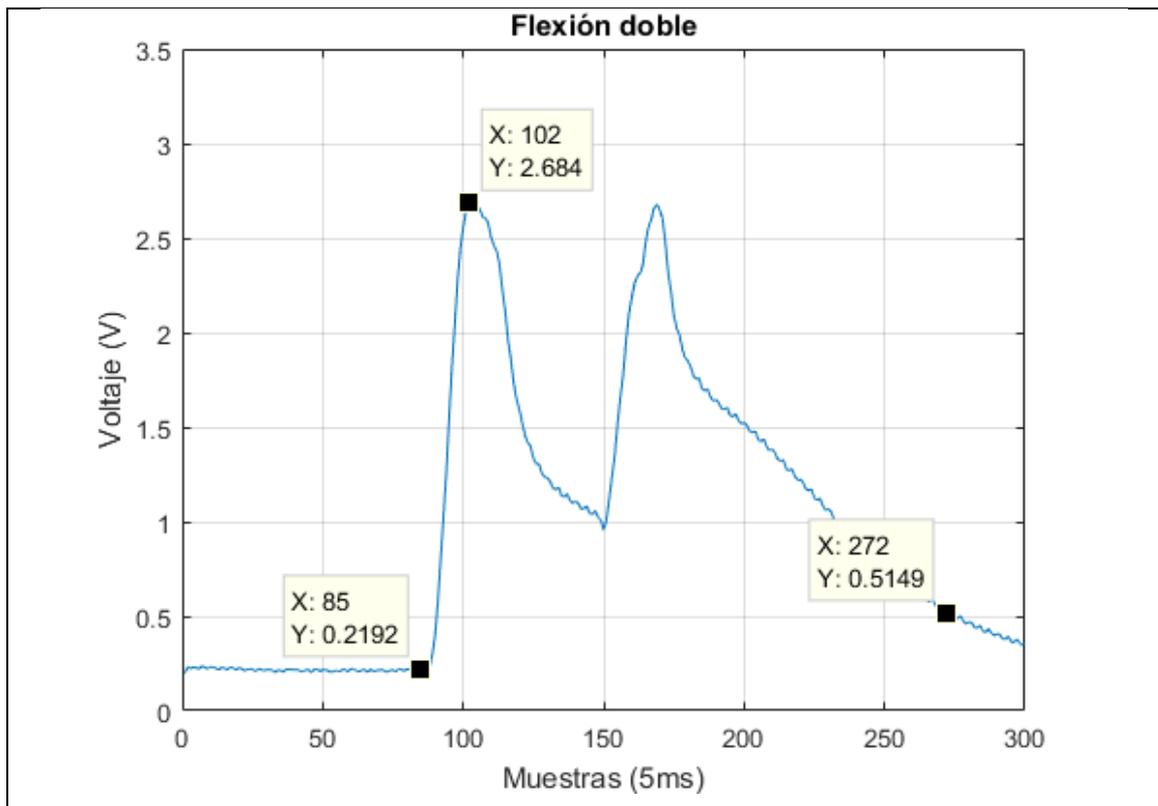


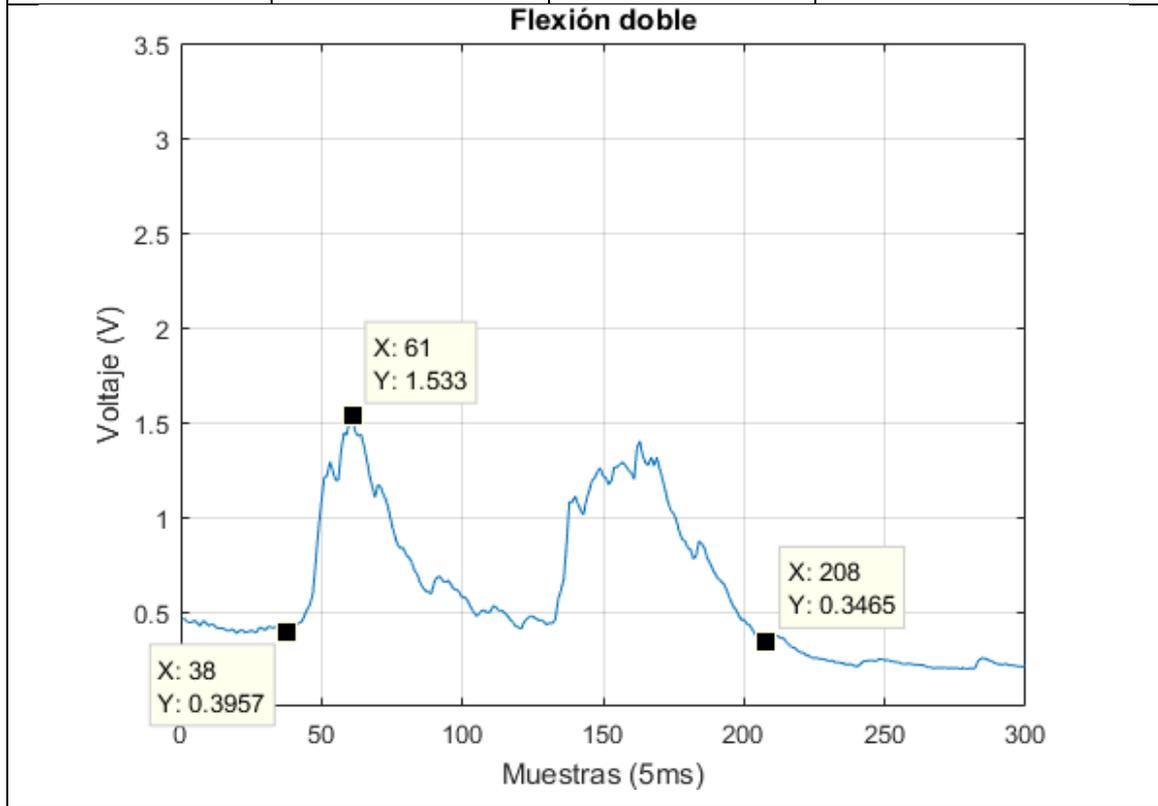
Figura 3.8 Tipos de contextura corporal  
Fuente: [61].  
Elaboración: Autores

Tabla 3.9 Resultados de las pruebas de la ventana de tiempo

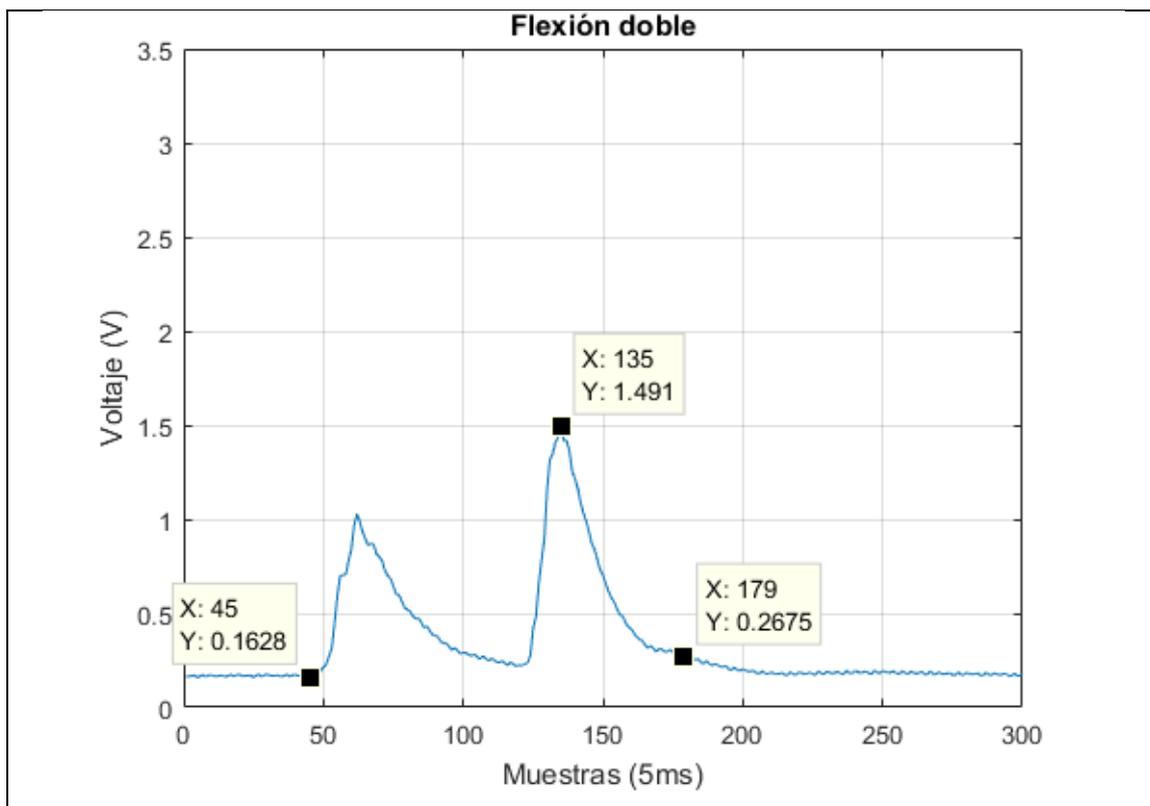
Edad	Contextura	# de muestras	Tiempo total
13	Ectomorfo	195	975ms
<b>Flexión doble</b>			
Edad	Contextura	# de muestras	Tiempo total
22	Ectomorfo	187	935ms



Edad	Contextura	# de muestras	Tiempo total
55	Endomorfo	170	850ms



Edad	Contextura	# de muestras	Tiempo total
68	Mesomorfo	134	670ms



Fuente: Autores  
 Elaboración: Autores

Tabla 3.10 Configuraciones de la RNA con distintos tiempos de muestreo

Tiempo de muestreo (ms)	Tamaño del vector de entrada	# de neuronas en la capa de entrada	# de neuronas primera capa oculta
30	27	27	54
25	32	32	64
20	40	40	80

Fuente: Autores  
 Elaboración: Autores

Considerando el número de neuronas y el tiempo de ejecución del entrenamiento se eligió el tiempo de muestreo de 30ms, ya que al realizar las pruebas con los tres tiempos de muestreo se obtuvo los mismos resultados, pero con distintos tiempos de ejecución, siendo el tiempo de muestreo de 30ms la configuración con menor tiempo de ejecución.

### 3.2.2. Implementación de la red neuronal artificial.

#### 3.2.2.1. Función de establecimiento de parámetros iniciales.

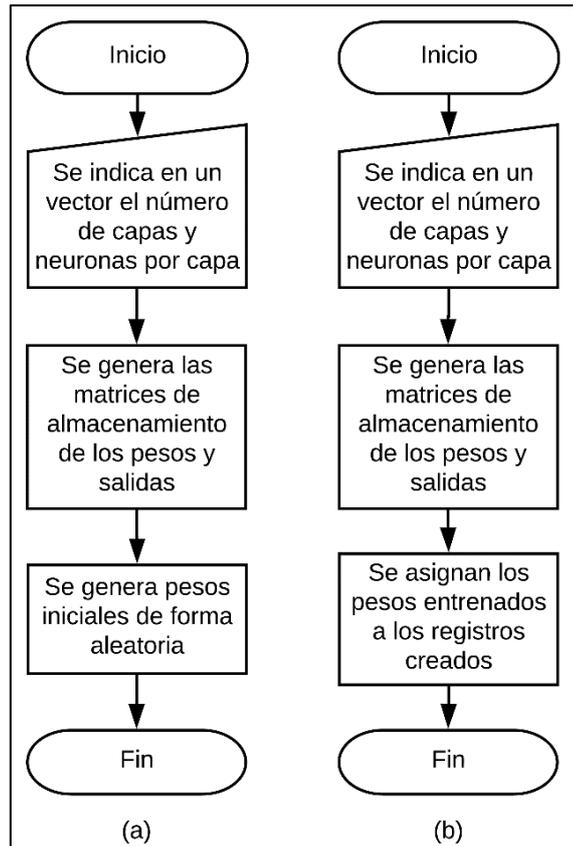


Figura 3.9 a) Diagrama de la función para el entrenamiento. b) Diagrama de la función para la red embebida.  
 Fuente: [58], [62]. Fuente: [58], [62].  
 Elaboración: Autores

Se creó una función que genere y establezca las dimensiones de las matrices, los pesos iniciales de forma aleatoria y modifique los valores anteriormente mencionados. La función establece los parámetros especificados en una variable global donde se especifica número de capas y número de neuronas por cada capa [62]. Como se observa en la Figura 3.9 se implementaron 2 funciones, la primera función (Figura 3.9-a) se implementó en un computador en el IDE “Codeblocks”, la segunda función (Figura 3.9-b) se implementó en el microcontrolador Atmega 328 y en el Arduino Due, eliminando la generación de pesos aleatorios iniciales, esto se debe a que no es necesario generarlos ya que se establecerán los pesos resultantes del entrenamiento en el computador. El código de esta función se muestra en el anexo B.

### 3.2.2.2. Función RNA.

Para la implementación de la RNA se realizó 2 funciones de la RNA, la primera función se la implementó con lenguaje C en un computador, esta función se la usa en fase de entrenamiento, debido a que el tiempo de entrenamiento en el microcontrolador es superior a 6 horas, por ello se decidió realizar el entrenamiento en un computador, y la segunda

función se la realizó con lenguaje C en un microcontrolador, inicialmente se implementó en el microcontrolador atmega 328 del Arduino pro mini, pero debido a limitaciones de memoria del microcontrolador se obtuvo problemas al embeber la RNA, ya que al existir más de 500 pesos entre las neuronas de todas las capas, se supera la memoria máxima del microcontrolador como se observa en la Figura 3.10.

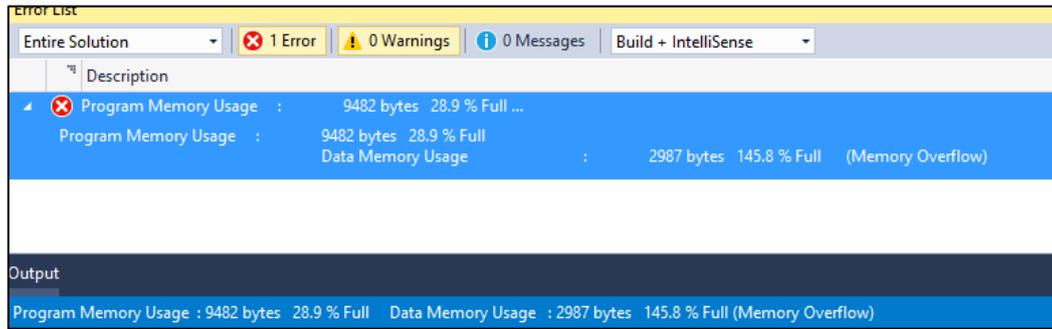


Figura 3.10 Error de memoria en el atmega 328  
 Fuente: Autores  
 Elaboración: Autores

Para ello se requirió un microcontrolador de mayores capacidades, siguiendo el trabajo [63], del proyecto mano esperanza, se optó por usar el microcontrolador SAM3X8E integrado en el Arduino Due y a diferencia del Atmega 328 que cuenta con 32KB de memoria, el Arduino DUE cuenta con 512KB de memoria flash [51], [52].

La función RNA embebida toma como parámetros de entrada los vectores de señales de entrada que se generan de la lectura del ADC y genera una matriz de salidas, como se muestra en la Figura 3.11, la red embebida culmina en la clasificación de un patrón de movimiento. Identificado el patrón se procede a realizar acciones en la mecánica de la prótesis para ejecutar el movimiento.

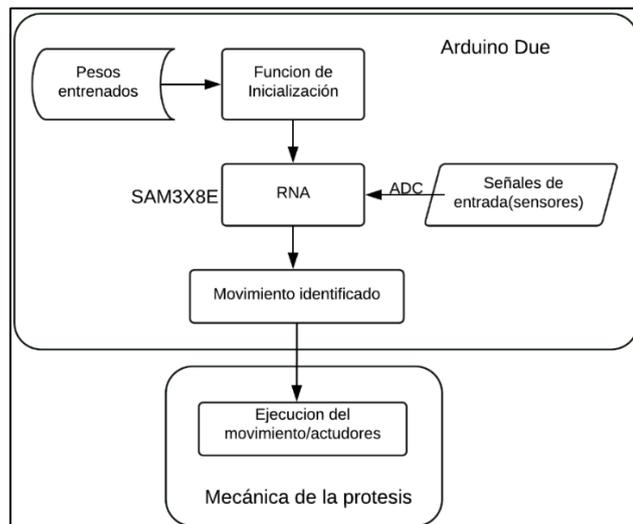


Figura 3.11 Esquema del módulo de identificación de patrones.  
 Fuente: Autores  
 Elaboración: Autores

### 3.2.3. Implementación del algoritmo de backpropagation.

Se implementó el algoritmo de backpropagation como una función en el IDE “Codeblocks”, la cual tiene como parámetros iniciales los vectores de entrada y los resultados deseados. Con las ecuaciones 3.2 y 3.3 la función calcula las variaciones de los pesos.

$$\Delta w_{ji} = \alpha * \delta_j x_{ji} \quad (3.2)$$

$$w_{ji} = \Delta w_{ji} + w_{ji} \quad (3.3)$$

Donde  $\Delta w_{ji}$  es la variación del peso,  $w_{ji}$  contiene el valor del peso actual,  $\alpha$  es un parámetro de aprendizaje constante que va entre 1 y 0, este valor sirve para mantener la estabilidad en la actualización de los pesos [58],  $\delta_j$  y  $x_{ji}$  son la variación delta j-ésima del error retropropagado y la salida de neurona ji-ésima.

### 3.2.4. Implementación del algoritmo de entrenamiento.

El algoritmo de entrenamiento se implementó como una función que agrupa las funciones anteriores y las ejecuta en un bucle, tal como se muestra en el diagrama de la Figura 3.13. Los datos de entrenamiento o la matriz de entradas son enviadas a la RNA para evaluar sus salidas y determinar un error, este error será utilizado por la función de aprendizaje para modificar el valor de los pesos. Se eligió un error cuadrático medio mínimo de  $1 * 10^{-8}$  para el cual se interrumpirá el bucle una vez que el error generado por la RNA sea menor o igual. En la Figura 3.12 se muestra como la función de entrenamiento llega al objetivo después de  $10^5$  épocas. Además, se puede observar como el error cambia conforme los pesos se van actualizado, pero existe un pico de subida del error debido a la inestabilidad en las primeras épocas del entrenamiento, generada por las distintas clases en las muestras de entrenamiento. En las épocas iniciales los pesos tienen un cambio muy lento y cuando los vectores de entrada cambian bruscamente de una clase a otra el error aumenta significativamente, pero conforme las épocas aumentan la actualización de los pesos se orientan a reducir el MSE. Finalizado el entrenamiento se realiza una prueba usando los datos de validación para verificar que los pesos generan un error mínimo en la RNA. Usando las fórmulas 3.4 y 3.5 podemos determinar qué tan precisa es la clasificación de patrones.

$$TER = 100\% * \frac{\#Pruebas\ erroneas}{\#Total\ de\ pruebas} \quad (3.4)$$

$$CA = 100\% * \frac{\#Pruebas\ correctas}{\#Total\ de\ pruebas} \quad (3.5)$$

La ecuación 3.4 nos arroja la tasa total de error (TER) de la RNA en porcentaje, es decir la probabilidad de que la RNA se equivoque al momento de identificar un patrón. Se consideró

como criterio obtener un TER menor o igual al 5%. La ecuación 3.5 es la probabilidad que tiene la RNA de identificar correctamente un patrón (CA). Una vez obtenido el TER deseado se considera que los pesos entrenados son los adecuados para ser almacenados en la memoria del microcontrolador para la RNA embebida.

Los pesos de la RNA embebida se almacenaron en una librería denominada "Pesos.h", este archivo se añadió al código con la herramienta "Atmel Studio" para asignar los pesos a la RNA embebida con el fin de permitir la variabilidad de la RNA, es decir poder modificar los pesos, el número de neuronas y el número de capas ocultas.

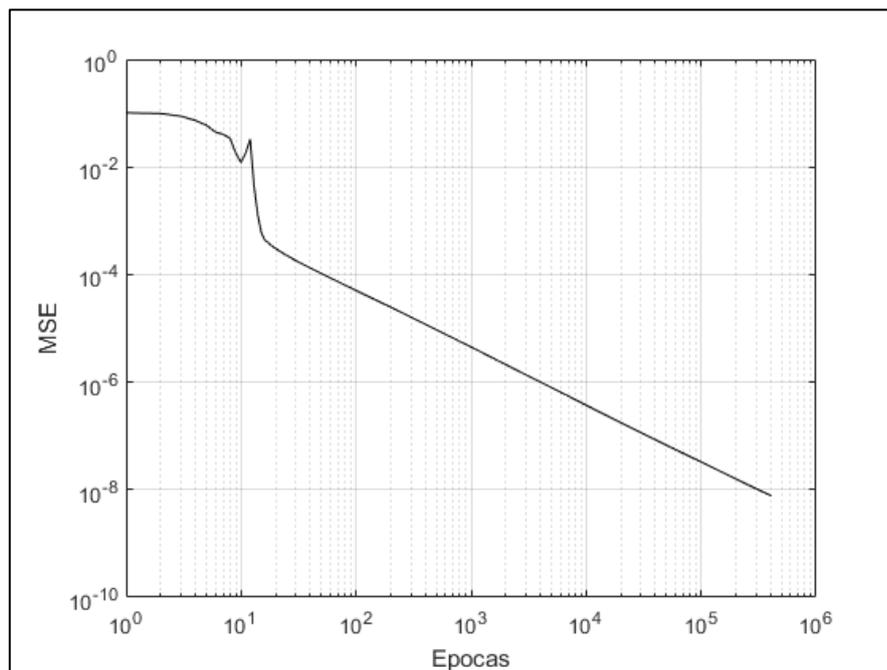


Figura 3.12 MSE en función del número de épocas

Fuente: Autores

Elaboración: Autores

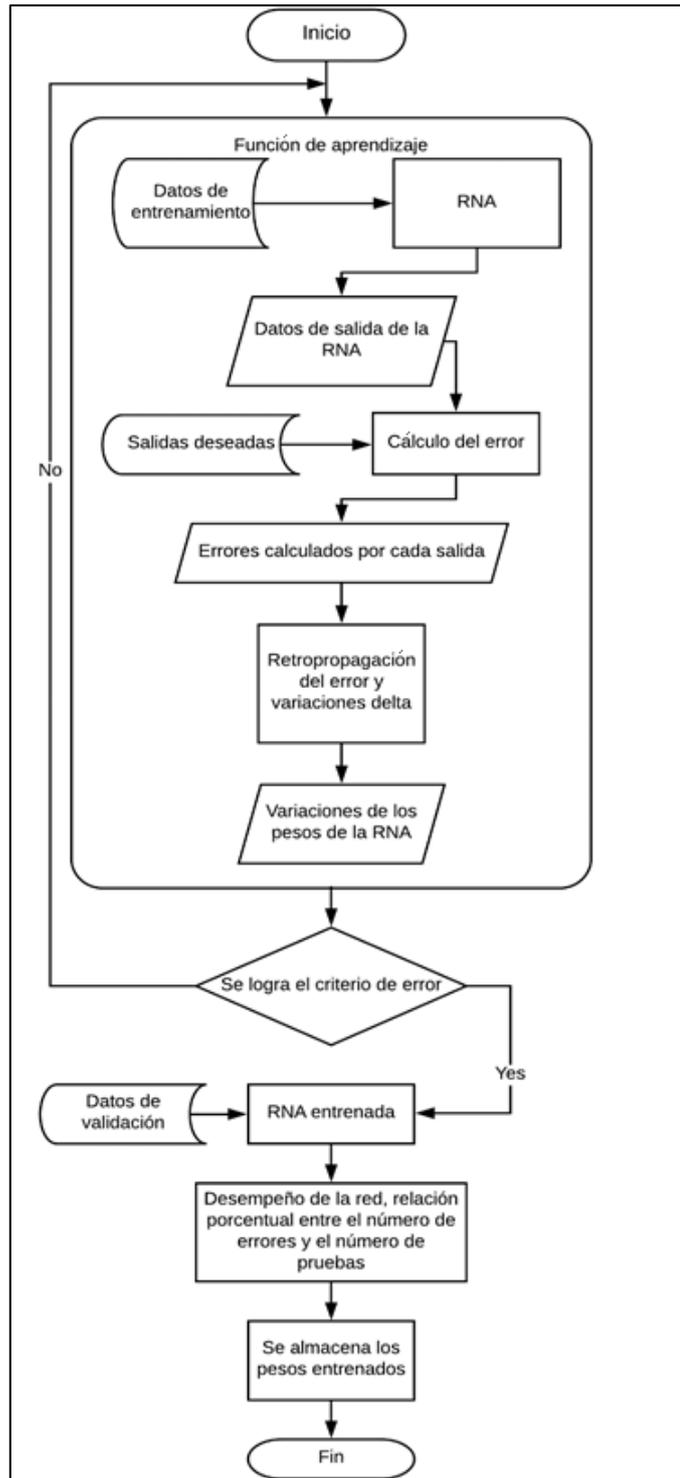


Figura 3.13 Diagrama del funcionamiento de la función de entrenamiento implementada.

Fuente: [56], [58], [62].

Elaboración: Autores

**CAPÍTULO 4**  
**EVALUACIÓN DEL DESEMPEÑO DEL SISTEMA EMBEBIDO**

En este capítulo se evalúa el desempeño del sistema y se analiza los resultados obtenidos en base a pruebas realizadas a 12 personas sin discapacidad motriz. Para la evaluación del sistema se obtuvo un banco de señales y la validación se la realizó mediante el cálculo de la precisión de clasificación y el uso de matrices de confusión.

#### 4.1. Metodología utilizada.

Para la formación del banco de señales se siguió la siguiente metodología:

- Se instruyó a los voluntarios sobre las acciones a efectuar para cada uno de los patrones elegidos en la sección 3.1.5.
- Se ubicó a cada persona en una posición relajada frente a un escritorio y con el brazo en reposo sobre el escritorio (ver Figura 4.1).
- Se le colocó el sensor en el músculo flexor radial del carpo.
- Se realizaron capturas de la señal EMG de prueba para determinar el nivel de entrenamiento de la persona. El entrenamiento consistió en realizar la flexión de la muñeca de forma consecutiva hasta lograr formar los patrones establecidos.
- Entendida y comprendida cada una de las acciones a realizar por parte de los participantes, se procedió a capturar las señales, para formar el banco de señales.

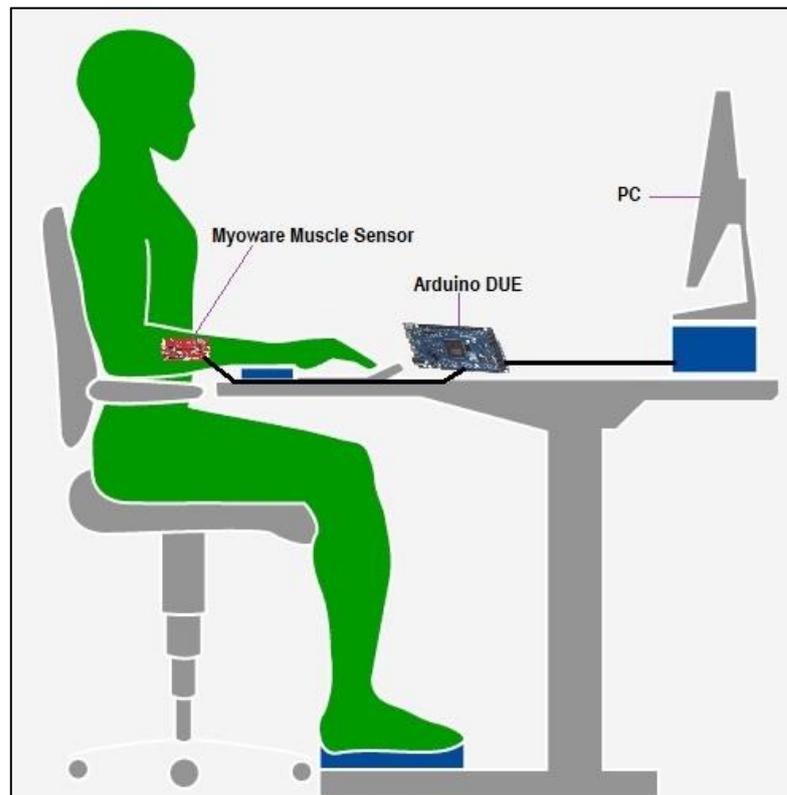


Figura 4.1 Diagrama de la metodología utilizada para la formación del banco de muestras

Fuente: Autores

Elaboración: Autores

#### 4.1.1. Banco de muestras.

Para la formación del banco de muestras se extrajo 10 señales EMG de cada clase o patrón a 12 personas de distintas edades y contextura corporal, como se puede observar en la Tabla 4.1.

Tabla 4.1 Características de usuarios de prueba para la extracción de señales EMG

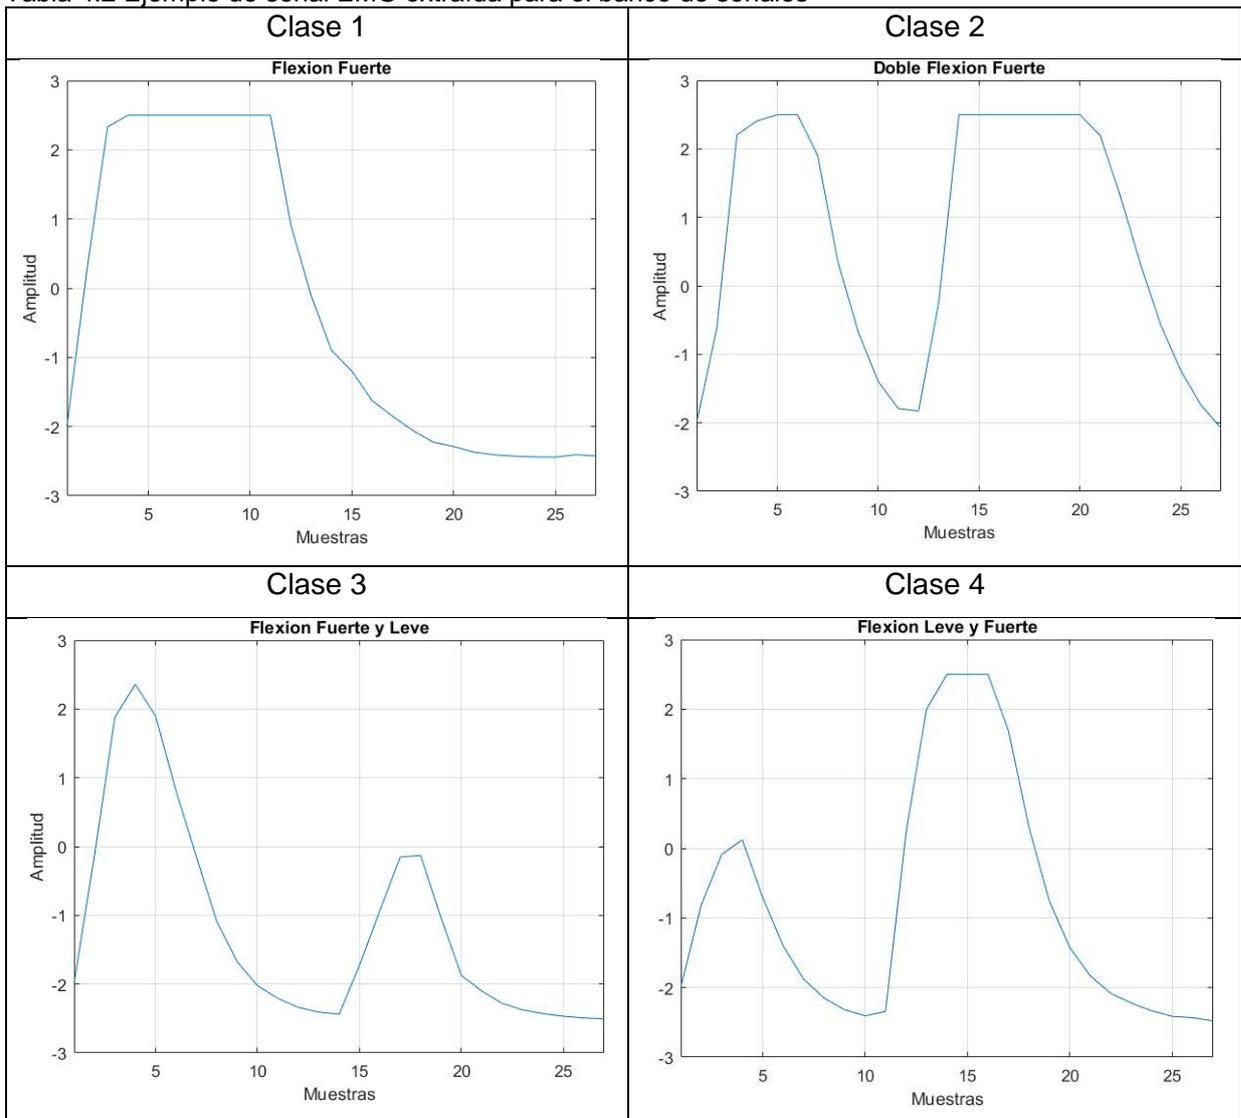
<b>N° Persona</b>	<b>Edad</b>	<b>Sexo</b>	<b>Contextura</b>
1	42	Femenino	Ectomorfo
2	11	Masculino	Ectomorfo
3	24	Femenino	Mesomorfo
4	24	Masculino	Mesomorfo
5	26	Masculino	Mesomorfo
6	26	Femenino	Ectomorfo
7	22	Masculino	Ectomorfo
8	53	Femenino	Endomorfo
9	26	Femenino	Mesomorfo
10	24	Masculino	Mesomorfo
11	22	Femenino	Mesomorfo
12	22	Masculino	Mesomorfo

Fuente: Autores

Elaboración: Autores

Se separó el banco de muestras en dos grupos, el primer grupo contiene el 70% de las señales extraídas de cada clase y de cada persona para realizar el entrenamiento de la red neuronal. El entrenamiento consiste en enseñar a la RNA a reconocer y distinguir cada uno de los patrones o clases. Y el segundo grupo contiene el 30% de las señales para la evaluación de la RNA. En la Tabla 4.2 se puede observar un ejemplo de las señales extraídas de cada clase. (Para mayor análisis de las señales obtenidas de cada persona observar el anexo C).

Tabla 4.2 Ejemplo de señal EMG extraída para el banco de señales



Fuente: Autores  
 Elaboración: Autores

#### 4.2. Validación del sistema de reconocimiento de patrones.

En la presente sección se describe como se realizó la evaluación del sistema de reconocimiento de patrones usando las técnicas de validación cruzada y validación online. En la siguiente figura se muestra la implementación del sistema embebido de reconocimiento de patrones, empleando el computador para la visualización y verificación de los resultados.

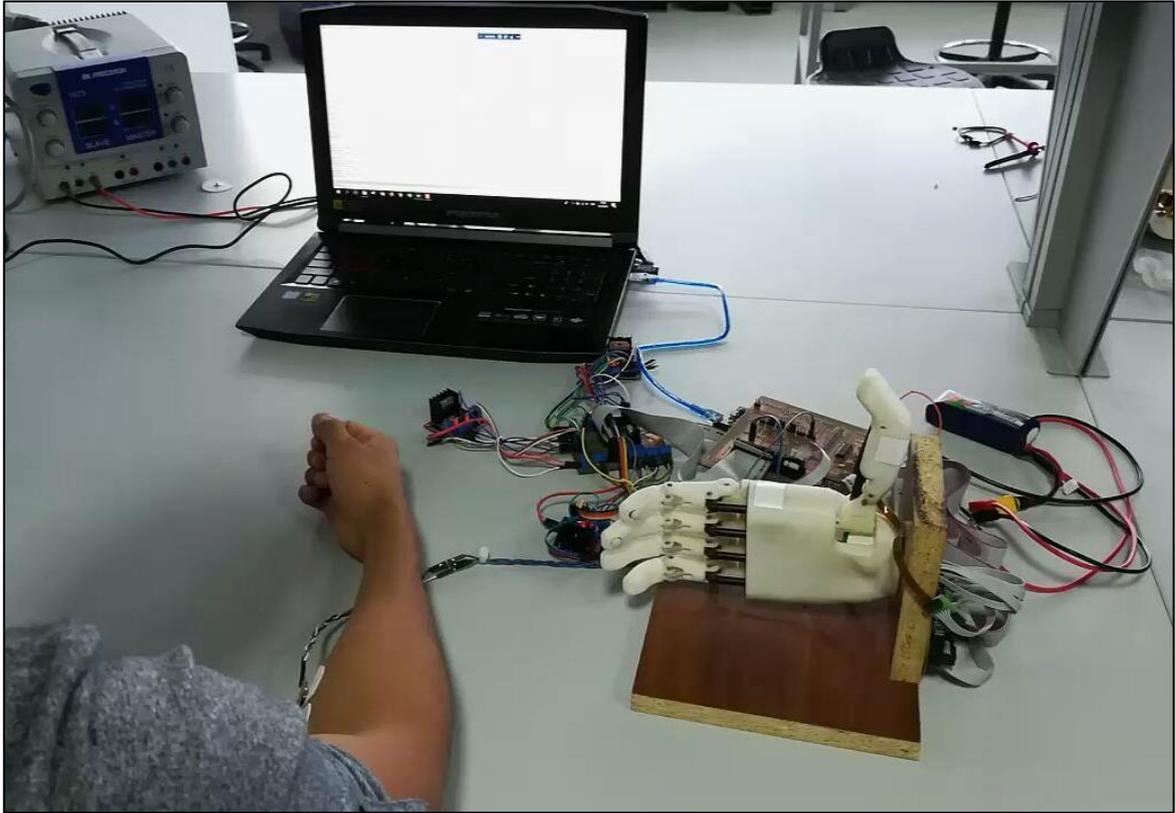


Figura 4. 2 Estación de validación

Fuente: Autores

Elaboración: Autores

#### 4.2.1. Validación cruzada.

Para asegurar el correcto funcionamiento de la fase de entrenamiento, se realizó la validación cruzada en el IDE Codeblocks. En la Tabla 4.3 se muestra como asignó las salidas deseadas a cada clase en la fase de entrenamiento. Como se observa en la Figura 4.3 el entrenamiento termina cuando se alcanza el error de  $1 * 10^{-8}$  e inmediatamente se evalúa la RNA con el 30% del banco de muestras y se visualiza la salida de la RNA y su correspondiente clase identificada.

Tabla 4.3 Asignación de las salidas de la RNA

Clase	Salida de la RNA
1	0-0-0-1
2	0-0-1-0
3	0-1-0-0
4	1-0-0-0

Fuente: Autores

Elaboración: Autores

Epoca: 0 Error: 0.186001 entrenando
Epoca: 100000 Error: 2.89401e-007 entrenando
Epoca: 200000 Error: 1.44636e-007 entrenando
Epoca: 300000 Error: 9.6399e-008 entrenando
Epoca: 400000 Error: 7.2286e-008 entrenando
Epoca: 500000 Error: 5.78206e-008 entrenando
Epoca: 600000 Error: 4.81783e-008 entrenando
Epoca: 700000 Error: 4.12917e-008 entrenando
Epoca: 800000 Error: 3.61273e-008 entrenando
Epoca: 900000 Error: 3.21108e-008 entrenando
Epoca: 1000000 Error: 2.88979e-008 entrenando
Epoca: 1100000 Error: 2.62693e-008 entrenando
Epoca: 1200000 Error: 2.40789e-008 entrenando
Epoca: 1300000 Error: 2.22256e-008 entrenando
Epoca: 1400000 Error: 2.06372e-008 entrenando
Epoca: 1500000 Error: 1.92606e-008 entrenando
Epoca: 1600000 Error: 1.80561e-008 entrenando
Epoca: 1700000 Error: 1.69934e-008 entrenando
Epoca: 1800000 Error: 1.60488e-008 entrenando
Epoca: 1900000 Error: 1.52036e-008 entrenando
Epoca: 2000000 Error: 1.4443e-008 entrenando
Epoca: 2100000 Error: 1.37549e-008 entrenando
Epoca: 2200000 Error: 1.31293e-008 entrenando
Epoca: 2300000 Error: 1.25581e-008 entrenando
Epoca: 2400000 Error: 1.20346e-008 entrenando
Epoca: 2500000 Error: 1.1553e-008 entrenando
Epoca: 2600000 Error: 1.11084e-008 entrenando
Epoca: 2700000 Error: 1.06967e-008 entrenando
Epoca: 2800000 Error: 1.03145e-008 entrenando
Epoca: 2888008 Error: 1e-008
1.- = 8.64381e-005 0.000104615 2.33815e-013 0.999861 CLASE 1: A_
2.- = 8.84997e-005 0.000102244 2.31702e-013 0.999863 CLASE 1: A_
3.- = 8.82751e-005 0.000102504 2.3169e-013 0.999863 CLASE 1: A_
4.- = 1.37665e-005 0.000662249 0.998399 4.87132e-011 CLASE 2: AA
5.- = 8.86261e-005 0.000102132 2.29914e-013 0.999864 CLASE 1: A_
6.- = 7.01291e-005 0.000127979 2.93771e-013 0.99983 CLASE 1: A_
7.- = 8.56453e-005 0.000105396 2.39294e-013 0.999858 CLASE 1: A_
8.- = 8.26471e-005 0.000108328 2.51948e-013 0.999851 CLASE 1: A_
9.- = 8.78451e-005 0.000102982 2.32722e-013 0.999862 CLASE 1: A_
10.- = 8.85803e-005 0.000102209 2.29752e-013 0.999864 CLASE 1: A_
11.- = 8.82703e-005 0.000102509 2.31558e-013 0.999863 CLASE 1: A_
12.- = 8.82363e-005 0.000102565 2.31351e-013 0.999863 CLASE 1: A_
13.- = 8.27622e-005 0.000109157 2.47184e-013 0.999854 CLASE 1: A_
14.- = 8.53222e-005 0.000106004 2.38938e-013 0.999859 CLASE 1: A_
15.- = 8.84047e-005 0.000102356 2.31348e-013 0.999863 CLASE 1: A_

Figura 4.3 Resultados de la validación cruzada

Fuente: Autores

Elaboración: Autores

#### 4.2.2. Validación online.

En la validación online del sistema, la señal EMG es capturada y enviada en tiempo real al microcontrolador para que la RNA realice el reconocimiento del patrón. Se realizaron las pruebas de validación con 12 personas aplicando la metodología de la sección 4.1, a cada persona se le pidió realizar 3 veces el patrón de cada clase.

#### 4.3. Análisis de resultados.

##### 4.3.1. Validación cruzada.

Como se observa en la Tabla 4.4 en la prueba 2 de la validación la clase 1 tiene un TER de 33.3% y se obtuvo un CA total para la prueba 2 de 91.6%. En las pruebas 9 y 10 la clase 3

tuvo un TER del 33.3% dándoles a ambas pruebas un CA de 91.6%, demostrando que la RNA tuvo más errores al reconocer la clase 3 con un CA promedio de 93.3% considerado como el peor resultado de la validación cruzada, seguida de la clase 1 con un CA promedio de 96.7%. La exactitud promedio que se obtuvo de todas las pruebas fue de 97.5% es decir un TER de 2.5%.

Tabla 4.4 Resultados de la validación cruzada

Prueba	Exactitud de clasificación(CA)				Media
	Clase 1	Clase 2	Clase 3	Clase 4	
1	100%	100%	100%	100%	100%
2	66.7%	100%	100%	100%	91.6%
3	100%	100%	100%	100%	100%
4	100%	100%	100%	100%	100%
5	100%	100%	100%	100%	100%
6	100%	100%	100%	100%	100%
7	100%	100%	100%	100%	100%
8	100%	100%	100%	100%	100%
9	100%	100%	66.7%	100%	91.6%
10	100%	100%	66.7%	100%	91.6%
Media	96.7%	100%	93.3%	100%	97.5%

Fuente: Autores  
Elaboración: Autores

#### 4.3.2. Validación online.

Los resultados obtenidos de la validación online se detallan en la Tabla 4.5, en la cual se ha calculado la exactitud de clasificación promedio de cada clase y persona. Se determinó que las clases 1,2 y 3 obtienen un CA de 97.22%, mientras que la clase 4 obtuvo un CA del 100% en todas las pruebas, en la Tabla 4.6 y Tabla 4.7 se presentan las matrices de confusión para el peor y mejor resultado, las matrices de confusión de las pruebas restantes se muestran en el anexo D. La exactitud promedio que se obtuvo en las pruebas de validación online fueron de 97.9% mayor a los resultados de la validación cruzada.

Tabla 4.5 Resultados de la validación online

Sujeto	Exactitud de clasificación(CA)				Media
	Clase 1	Clase 2	Clase 3	Clase 4	
1	100%	100%	100%	100%	100%

2	100%	100%	100%	100%	100%
3	100%	100%	66.7%	100%	91.6%
4	66.7%	66.7%	100%	100%	83.3%
5	100%	100%	100%	100%	100%
6	100%	100%	100%	100%	100%
7	100%	100%	100%	100%	100%
8	100%	100%	100%	100%	100%
9	100%	100%	100%	100%	100%
10	100%	100%	100%	100%	100%
11	100%	100%	100%	100%	100%
12	100%	100%	100%	100%	100%
Media	97.22%	97.22%	97.22%	100%	97.9%

Fuente: Autores  
Elaboración: Autores

Tabla 4.6 Matriz de confusión para el peor resultado

Clase	1	2	3	4
1	66.7%	0	0	0
2	0	66.7%	0	33.7%
3	0	0	100%	0
4	0	0	0	100%

Fuente: Autores  
Elaboración: Autores

Tabla 4.7 Matriz de confusión para el mejor resultado

Clase	1	2	3	4
1	100%	0	0	0
2	0	100%	0	0
3	0	0	100%	0
4	0	0	0	100%

Fuente: Autores  
Elaboración: Autores

Como se muestra en la Tabla 4.6 se obtuvo un falso positivo, es decir la RNA clasificó el patrón de la clase 2 como clase 4 y un error de clasificación con el patrón de la clase 1 el cual no fue reconocido por la RNA como una clase, estos se deben a la falta de entrenamiento de la participante sobre cada uno de los movimientos a realizar.

En la siguiente figura se muestra los resultados obtenidos al realizar la validación cruzada y la validación online. Al comparar estas dos validaciones se puede observar que la clase 4 obtiene el 100% de exactitud en ambas técnicas de validación, la clase 1 obtuvo resultados semejantes en ambos casos, se llegó al 96.7 y 96.9% de exactitud respectivamente, la clase

2 tuvo el 100% de exactitud en la validación cruzada mientras que en la validación online 96.7% y la clase 3 obtuvo menor porcentaje de exactitud en la validación cruzada en comparación con los resultados de la validación online.

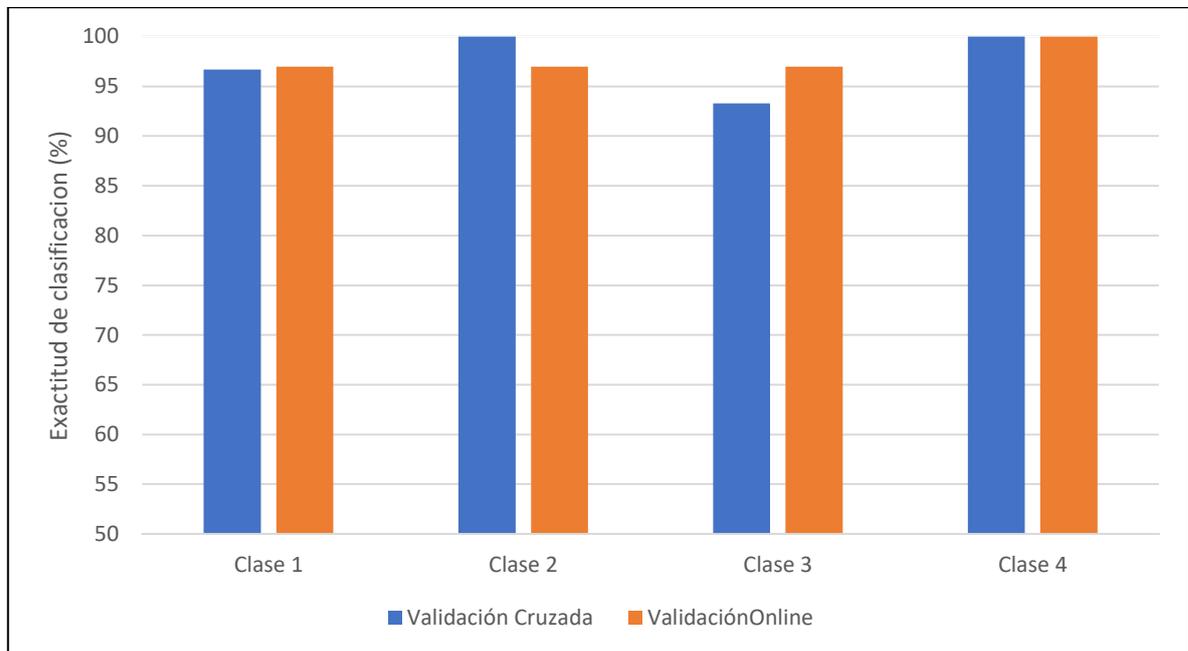


Figura 4.4 Comparación de exactitud entre la validación cruzada y validación online  
Fuente: Autores  
Elaboración: Autores

## CONCLUSIONES

En este trabajo se utilizaron electrodos de gel superficiales para la extracción de señales EMG por la comodidad en la colocación y facilidad de uso para los usuarios, al emplear electrodos superficiales la extracción de la señal no se puede concentrar en un solo músculo, es decir existirá interferencia con señales provenientes de músculos adyacentes. Para disminuir la interferencia en la extracción de la señal se colocó los electrodos y la tarjeta de acondicionamiento en dirección del antebrazo (sentido codo-muñeca) y la referencia se colocó cerca o sobre el codo.

Al realizar entrenamiento previo de los participantes, sobre los movimientos a realizar tanto para la fase de formación del banco de muestras, como para la validación del sistema, se determinó que mientras más veces se repite el ejercicio o movimientos de forma continua (una repetición tras otra sin descanso entre repeticiones), se produce agotamiento conocido como fatiga muscular. Al producirse esta fatiga muscular afecta directamente a la extracción de señales EMG, ya que la señal se torna inestable y se detecta movimientos involuntarios por parte del participante.

La fase de entrenamiento de la RNA permitió extraer las características comunes de las señales de cada clase, facilitando el reconocimiento y clasificación de señales independientes a las señales de entrenamiento, de tal manera que la señal de entrada no debe ser exactamente igual a la entrenada para que sea clasificada.

En base a los resultados obtenidos de las técnicas de validación se concluyó que la clase 3 es la clase con mayor probabilidad de error debido a la dificultad de realizar el patrón correctamente y la semejanza que existe con las clases 2 y 4. La clase 4 logró tener un CA de 100% en ambas técnicas de validación concluyendo como la clase con menor probabilidad de error. Tras las pruebas realizadas para la validación de la RNA embebida se determinó que el 65% de los errores fueron falsos negativos y el 35% fueron errores entre clases.

## RECOMENDACIONES

En el desarrollo de este proyecto al momento de extraer las señales EMG se dieron algunos errores, los mismos que se originaron por la mala colocación del electrodo de referencia. Por esta razón se recomienda que para asegurar que la señal sea estable, se debe colocar de forma adecuada electrodo de referencia. Es decir, debe ser colocado en una región donde no exista actividad muscular al momento de realizar el movimiento.

Al realizar la flexión fuerte de la muñeca, se lo debe hacer con una fuerza moderada, de tal forma que, al flexionar la muñeca fuerte y repetidas veces, no sea un proceso doloroso o agotador para el usuario.

Para que la RNA clasifique movimientos más naturales se recomienda aumentar el número de canales, el aumento permite obtener mayor cantidad de señales EMG provenientes de diferentes músculos que intervienen al realizar un movimiento.

Para mejorar la interpretación las señales EMG se recomienda realizar una etapa de filtrado adicional a la del sensor para reducir el error la clasificación de patrones causado por señales falsas resultantes del ruido en el sistema.

## BIBLIOGRAFÍA

- [1] I. M. Alguacil, F. Molina, and M. Gómez, "Repercusión del ejercicio físico en el amputado," *Arch. Med. del Deport.*, vol. 27, no. 138, pp. 291–302, 2010.
- [2] M. L. Ocampo, L. M. Henao, and L. Vásquez, "Amputación de miembro inferior: Cambios funcionales, inmovilización y actividad física," *Borradores Investig. Ser. Doc. Rehabil. y Desarro. Humano, ISSN 1794-1318, No. 42 (Marzo 2010)*, 2010.
- [3] R. Ceres, J. L. Pons, L. Calderón, and J. Moreno, "La robótica en la discapacidad. Desarrollo de la prótesis diestra de extremidad inferior manus-hand," *Rev. Iberoam. Automática e Informática Ind. RIAI*, vol. 5, no. 2, pp. 60–68, 2008.
- [4] C. A. Quinayás-Burgos and C. A. Gavia-López, "Sistema de identificación de intención de movimiento para el control mioeléctrico de una prótesis de mano robótica," *Ing. y Univ.*, vol. 19, no. 1, 2015.
- [5] E. Biddiss and T. Chau, "Upper-Limb Prosthetics: Critical Factors in Device Abandonment," *Am. J. Phys. Med. Rehabil.*, vol. 86, no. 12, 2007.
- [6] "Consejo Nacional para la Igualdad de Discapacidades – CONADIS," 2018. [Online]. Available: <http://www.consejodiscapacidades.gob.ec/>. [Accessed: 15-Apr-2018].
- [7] C. Cipriani, F. Zaccone, S. Micera, and M. C. Carrozza, "On the Shared Control of an EMG-Controlled Prosthetic Hand: Analysis of User-Prosthesis Interaction," *Trans. Rob.*, vol. 24, no. 1, pp. 170–184, 2008.
- [8] H. A. Romo, J. C. Realpe, and P. E. Jojoa, "Análisis de señales EMG superficiales y su aplicación en control de prótesis de mano," *Rev. Av. en Sist. e informática*, vol. 4, no. 1, 2007.
- [9] A. Subasi, "Classification of EMG signals using combined features and soft computing techniques," *Appl. Soft Comput. J.*, vol. 12, no. 8, pp. 2188–2198, Aug. 2012.
- [10] E. Scheme and K. Englehart, *Electromyogram pattern recognition for control of powered upper-limb prostheses: State of the art and challenges for clinical use*, vol. 48. 2011.
- [11] O. W. Samuel *et al.*, "Pattern recognition of electromyography signals based on novel time domain features for amputees' limb motion classification," *Comput. Electr. Eng.*, Apr. 2017.
- [12] C. M. Duran Acevedo and J. E. J. Duarte, "Development of an embedded system for classification of EMG signals," in *2014 3rd International Congress of Engineering Mechatronics and Automation, CIIMA 2014 - Conference Proceedings*, 2014.
- [13] K. Akhmadeev, E. Rampone, T. Yu, Y. Aoustin, and E. Le Carpentier, "A testing system for a real-time gesture classification using surface EMG," *IFAC-PapersOnLine*,

- vol. 50, no. 1, pp. 11498–11503, Jul. 2017.
- [14] L. F. Marín Quevedo, V. Narváez, and E. Iván, “Análisis de las señales electromiográficas para implementar un prototipo de rehabilitación de la articulación tibioperoneoastragalina a través de un clasificador de redes neuronales artificiales.” Universidad de las Fuerzas Armadas ESPE Extensión Latacunga. Carrera de Ingeniería Mecatrónica., 2017.
- [15] C. A. Q. Burgos and O. A. V. Albán, “Diseño y construcción de una prótesis robotica de mano funcional adaptada a varios agarres,” *Popayán, enero del*, 2010.
- [16] D. A. R. Lopez, M. A. López, J. E. D. Sánchez, and H. L. Correa, “IMPLEMENTACIÓN EN FPGA DE UN CLASIFICADOR DE MOVIMIENTOS DE LA MANO USANDO SEÑALES EMG,” *Redes Ing.*, vol. 6, no. 1, pp. 85–94, 2015.
- [17] J. Villarejo, “Detección de la intención de movimiento durante la marcha a partir de señales electromiográficas,” 2011.
- [18] L. Cortes Carvajal, M. Guerrero Doria, J. Realpe, and H. Romo, “SISTEMA DETECTOR DE INTENCIÓN DE MOVIMIENTO A PARTIR DE SEÑALES ELECTROMIOGRÁFICAS SUPERFICIALES,” *Rev. PUENTE Científica*, vol. 7, no. 2, 2014.
- [19] C. Calderon-Cordova, C. Ramírez, V. Barros, P. A. Quezada-Sarmiento, and L. Barba-Guamán, “EMG signal patterns recognition based on feedforward Artificial Neural Network applied to robotic prosthesis myoelectric control,” in *Future Technologies Conference (FTC)*, 2016, pp. 868–875.
- [20] C. A. Calderon, C. Ramirez, V. Barros, and G. Punin, “Design and Deployment of Grasp Control System applied to robotic hand prosthesis,” *IEEE Lat. Am. Trans.*, vol. 15, no. 2, pp. 181–188, 2017.
- [21] CCM, “Radio - Definición Definición,” p. 2016, 2016.
- [22] A. Galiano, “APUNTES DE ANATOMIA.” [Online]. Available: <http://www.iqb.es/cbasicas/anatomia/es003.htm>.
- [23] “Músculos del antebrazo,” *Información, Banco de objetos de aprendizaje y de información.* [Online]. Available: <http://aprendeonline.udea.edu.co/lms/ova/mod/resource/view.php?inpopup=true&id=617>. [Accessed: 21-Mar-2018].
- [24] “Músculo pronador redondo.” [Online]. Available: <https://www.imaios.com/es/e-Anatomy/Estructuras-anatomicas/Musculo-pronador-redondo>. [Accessed: 21-Mar-2018].
- [25] “Músculo flexor radial del carpo.” [Online]. Available: <https://www.imaios.com/es/e-Anatomy/Estructuras-anatomicas/Musculo-flexor-radial-del-carpo>. [Accessed: 21-Mar-

- 2018].
- [26] “Músculo flexor radial del carpo o palmar mayor | iinmed.” [Online]. Available: <http://www.iinmed.com/2016/06/musculo-flexor-radial-del-carpo-o.html>. [Accessed: 21-Mar-2018].
- [27] “Músculo flexor cubital del carpo.” [Online]. Available: <https://www.imaios.com/es/e-Anatomy/Estructuras-anatomicas/Musculo-flexor-cubital-del-carpo>. [Accessed: 21-Mar-2018].
- [28] “Músculo flexor cubital del carpo | iinmed.” [Online]. Available: <http://www.iinmed.com/2016/06/musculo-flexor-cubital-del-carpo.html>. [Accessed: 21-Mar-2018].
- [29] “MI REVISTA MEDICA.” [Online]. Available: <http://mirevistamedica.net/Músculo-Flexor-común-superficial-de-los-dedos.php>. [Accessed: 21-Mar-2018].
- [30] “Músculo braquiorradial | iinmed.” [Online]. Available: <http://www.iinmed.com/2016/06/musculo-braquiorradial.html>. [Accessed: 21-Mar-2018].
- [31] “Músculo extensor radial largo del carpo | iinmed.” [Online]. Available: <http://www.iinmed.com/2016/06/musculo-extensor-radial-largo-del-carpo.html>. [Accessed: 21-Mar-2018].
- [32] “Musculo extensor radial corto.” [Online]. Available: [https://www.ugr.es/~dlcruz/musculos/musculos/extensor radial corto.htm](https://www.ugr.es/~dlcruz/musculos/musculos/extensor%20radial%20corto.htm). [Accessed: 21-Mar-2018].
- [33] “Músculo extensor radial corto del carpo | iinmed.” [Online]. Available: <http://www.iinmed.com/2016/06/musculo-extensor-radial-corto-del-carpo.html>. [Accessed: 21-Mar-2018].
- [34] Dolopedia, “Anatomía del nervio cubital,” 15/06/2017. [Online]. Available: <https://dolopedia.com/categoria/anatomia-del-nervio-cubital>. [Accessed: 21-Mar-2018].
- [35] Healthwise, “Nervios del Brazo,” 2010. [Online]. Available: [http://content.seton.net/healthwise/articles/nervios\\_del\\_brazo\\_nerves\\_of\\_the\\_arm\\_health](http://content.seton.net/healthwise/articles/nervios_del_brazo_nerves_of_the_arm_health). [Accessed: 21-Mar-2018].
- [36] E. Herrera, C. Anaya, A. M. Abril, Y. C. Avellaneda, A. M. Cruz, and W. M. Lozano, “Descripción anatómica del plexo braquial,” *Rev. la Univ. Ind. Santander. Salud*, vol. 40, no. 2, 2008.
- [37] M. V Masson, “Fundamentos de Tratamiento en las fracturas de la diáfisis humeral con y sin lesiones del nervio radial,” *Ene*, 2012.
- [38] Dolopedia, “Anatomía del nervio mediano,” 24/11/2017. [Online]. Available: <https://dolopedia.com/articulo/anatomia-del-nervio-mediano-1#.WnUXpKjiZPY>.

- [Accessed: 21-Mar-2018].
- [39] R. R. Mario, V. B. Ángel, V. G. Gustavo, H. G. Edgar, and J. R. Luis, “Detección y Acondicionamiento de Señales Mioeléctricas,” 2011.
- [40] A. Viladot, “Lecciones básicas de biomecánica del aparato locomotor,” *Editor. Espringer-Verlag Ibérica. Barcelona-España*, 2001.
- [41] A. F. Ruiz, F. J. Brunetti, E. Rocon, A. Forner-Cordero, J. L. Pons, and G. de Bioingeniería, “Adquisición y procesamiento de información EMG en el modelado de sistemas biológicos,” *Jornadas de Automática*, 2007.
- [42] E. Hidalgo and A. Córdova, “La electromiografía (EMG) como método de valoración de la Fatiga Muscular,” Universidad de Valladolid, 2015.
- [43] P. R. Merletti and P. dr. G. R. and D. C. Disselhorst-Klug, “SENIAM.” [Online]. Available: <http://www.seniam.org/>. [Accessed: 12-Feb-2018].
- [44] M. A. V. Aparicio, “Electromiografía cinesiología,” *Rehabilitación*, vol. 39, no. 6, pp. 255–264, 2005.
- [45] L. A. Zabala Aguiar, “Desarrollo de un sistema de adquisición y procesamiento de señales electromiográficas con Matlab para la identificación de los movimientos extensión, flexión, pronación y supinación de un brazo humano.” Escuela Superior Politécnica de Chimborazo, 2017.
- [46] Pololu Corporation, “Pololu - Sensor muscular MyoWare.” [Online]. Available: <https://www.pololu.com/product/2732>. [Accessed: 18-Nov-2017].
- [47] SparkFun, “Muscle Sensor v3 Kit.” [Online]. Available: [https://cdn.sparkfun.com/datasheets/Sensors/Biometric/Muscle\\_Sensor\\_v3\\_Users\\_Manual.pdf](https://cdn.sparkfun.com/datasheets/Sensors/Biometric/Muscle_Sensor_v3_Users_Manual.pdf). [Accessed: 18-Nov-2017].
- [48] Biometrics Ltd, “Surface EMG Sensor.” [Online]. Available: [http://www.biometricsltd.com/surface-emg-sensor.htm?gclid=CjwKCAiA9f7QBRBpEiwApLGUitYZzJzuMdPjwKOratMe4r568FGKiN\\_yFi1mZx41g0vT7HZzycwhxRoC\\_XAQAvD\\_BwE](http://www.biometricsltd.com/surface-emg-sensor.htm?gclid=CjwKCAiA9f7QBRBpEiwApLGUitYZzJzuMdPjwKOratMe4r568FGKiN_yFi1mZx41g0vT7HZzycwhxRoC_XAQAvD_BwE). [Accessed: 18-Nov-2017].
- [49] SEED Studio, “Grove - EMG Detector.” [Online]. Available: [http://wiki.seeed.cc/Grove-EMG\\_Detector/](http://wiki.seeed.cc/Grove-EMG_Detector/). [Accessed: 18-Nov-2017].
- [50] Sparkfun, “SparkFun USB to Serial Breakout - FT232RL,” 2015. [Online]. Available: <https://www.sparkfun.com/products/12731>.
- [51] ARDUINO, “ARDUINO PRO MINI 328.” [Online]. Available: <http://arduino.cl/arduino-pro-mini-328/>. [Accessed: 19-Nov-2017].
- [52] tdrobótica, “ARDUINO DUE.” [Online]. Available: <http://tdrobotica.co/arduino-due/31.html>. [Accessed: 19-Nov-2017].
- [53] H. B. Demuth, M. H. Beale, O. De Jess, and M. T. Hagan, *Neural Network Design*,

- 2nd ed. USA: Martin Hagan, 2014.
- [54] J. A. Alarcón Ramírez, L. E. Ruiz Cueva, and J. L. Tello Puerta, "Diseño e implementación de un sistema de adquisición y procesamiento de señales mioeléctricas para el reconocimiento en tiempo real de la contracción de los bíceps y tríceps braquiales orientado a la manipulación de un brazo robótico de tres grados de lib." Universidad Peruana de Ciencias Aplicadas (UPC).
- [55] A. M. F. Souza and F. M. Soares, *Neural network programming with Java*. Packt Publishing Ltd, 2016.
- [56] C. M. Bishop, *Neural networks for pattern recognition*. Oxford university press, 1995.
- [57] V. G. Maltarollo, K. M. Honório, and A. B. F. da Silva, "Applications of Artificial Neural Networks in Chemical Problems," in *Artificial Neural Networks - Architectures and Applications*, K. Suzuki, Ed. Rijeka: InTech, 2013.
- [58] T. Masters, *Practical neural network recipes in C++*. Morgan Kaufmann, 1993.
- [59] "Kendall™ ECG Electrodes Product Data Sheet Arbo."
- [60] "Advancer Technologies, LLC: [DIY] Conductive Fabric Electrodes." [Online]. Available: <http://www.advancertechnologies.com/2013/03/diy-conductive-fabric-electrodes.html>. [Accessed: 20-Dec-2017].
- [61] J. M. Martínez-sanz, A. Urdampilleta, J. Guerrero, and B. Vanesa, "El somatotipo-morfología en los deportistas. ¿Cómo se calcula? ¿Cuáles son las referencias internacionales para comparar con nuestros deportistas?," *EF Deport.*, vol. 159, no. 3, pp. 26–31, 2011.
- [62] C. Tejpal Singh, "Back-propagation Neural Net - CodeProject," 28 Mar 2006, 2006. .
- [63] J. O. Banegas Rojas and S. R. Sarmiento Sotomayor, "Diseñar y desarrollar un controlador embebido basado en PID aplicado a la regulación de fuerza de una mano robótica," 2017.

## **ANEXOS**

## ANEXO A

Código en C++ de la función de calibración, etapa de ajuste de la señal EMG y adquisición de señales

```
void Calibracion()
{
    min=4000;//Iniciado en el valor más alto
    Enviar_UART("Realice movimiento hacia PUNIO ");
    _Delay_ms(400);
    Enviar_UART("\n");
    Enviar_UART("ya");
    Enviar_UART("\n");
    Enviar_UART(" 1      2      3");
    Enviar_UART("\n");
    _Delay_ms(70);
    for (int z=0;z<90;z++)
    {
        vmaxs1[z]=Leer_ADC(A1);
        if(z>0){
            sprintf(buffer, "%f", vmaxs1[z]);
            Enviar_UART(buffer);
            Enviar_UART("\n ");
            if (vmaxs1[z]>mayor1)//se compara los valores para determinar
            {mayor1=vmaxs1[z]; }//el máximo y mínimo de la persona
            if (vmaxs1[z]<min){
                min=vmaxs1[z];}
            _Delay_ms(30);}
        }min=min+mayor1*0.1;
        mayor1+=mayor1*0.1;
        sprintf(buffer, "%f", mayor1);
        Enviar_UART("\n");
        Enviar_UART(" VALOR MAXIMO: ");
        Enviar_UART(buffer);
        Enviar_UART("\n");
        sprintf(buffer, "%f", min);
        Enviar_UART("\n");
        Enviar_UART(" VALOR Min: ");
        Enviar_UART(buffer);
        Enviar_UART("\n");
        _Delay_ms(1000);
    }
}

for (int x=0;x<27;)//se establece la ventana de 800ms
{//se realiza un escalado de la señal
    s1[x]=(((Leer_ADC(A1)-min)/((mayor1-min)/20))-11)/4.5;
    if(s1[x]>-1.0 && d==0)//condición para trabajar solo cuando se
    {
        sprintf(buffer, "%f",s1[x]); // realice patrón
        Enviar_UART(buffer);
        Enviar_UART(" * ");
        d=1;
    }
    if(d==1){
        vectE[x]=s1[x];//se almacena el patrón en un vector
        sprintf(buffer, "%f", vectE[x]);
        Enviar_UART(buffer);//se muestra el patrón vía serial
        Enviar_UART(", ");
        _Delay_ms(30);
        x++;}
}
```

## ANEXO B

Funciones de activación sigmoide, inicialización de la RNA y RNA

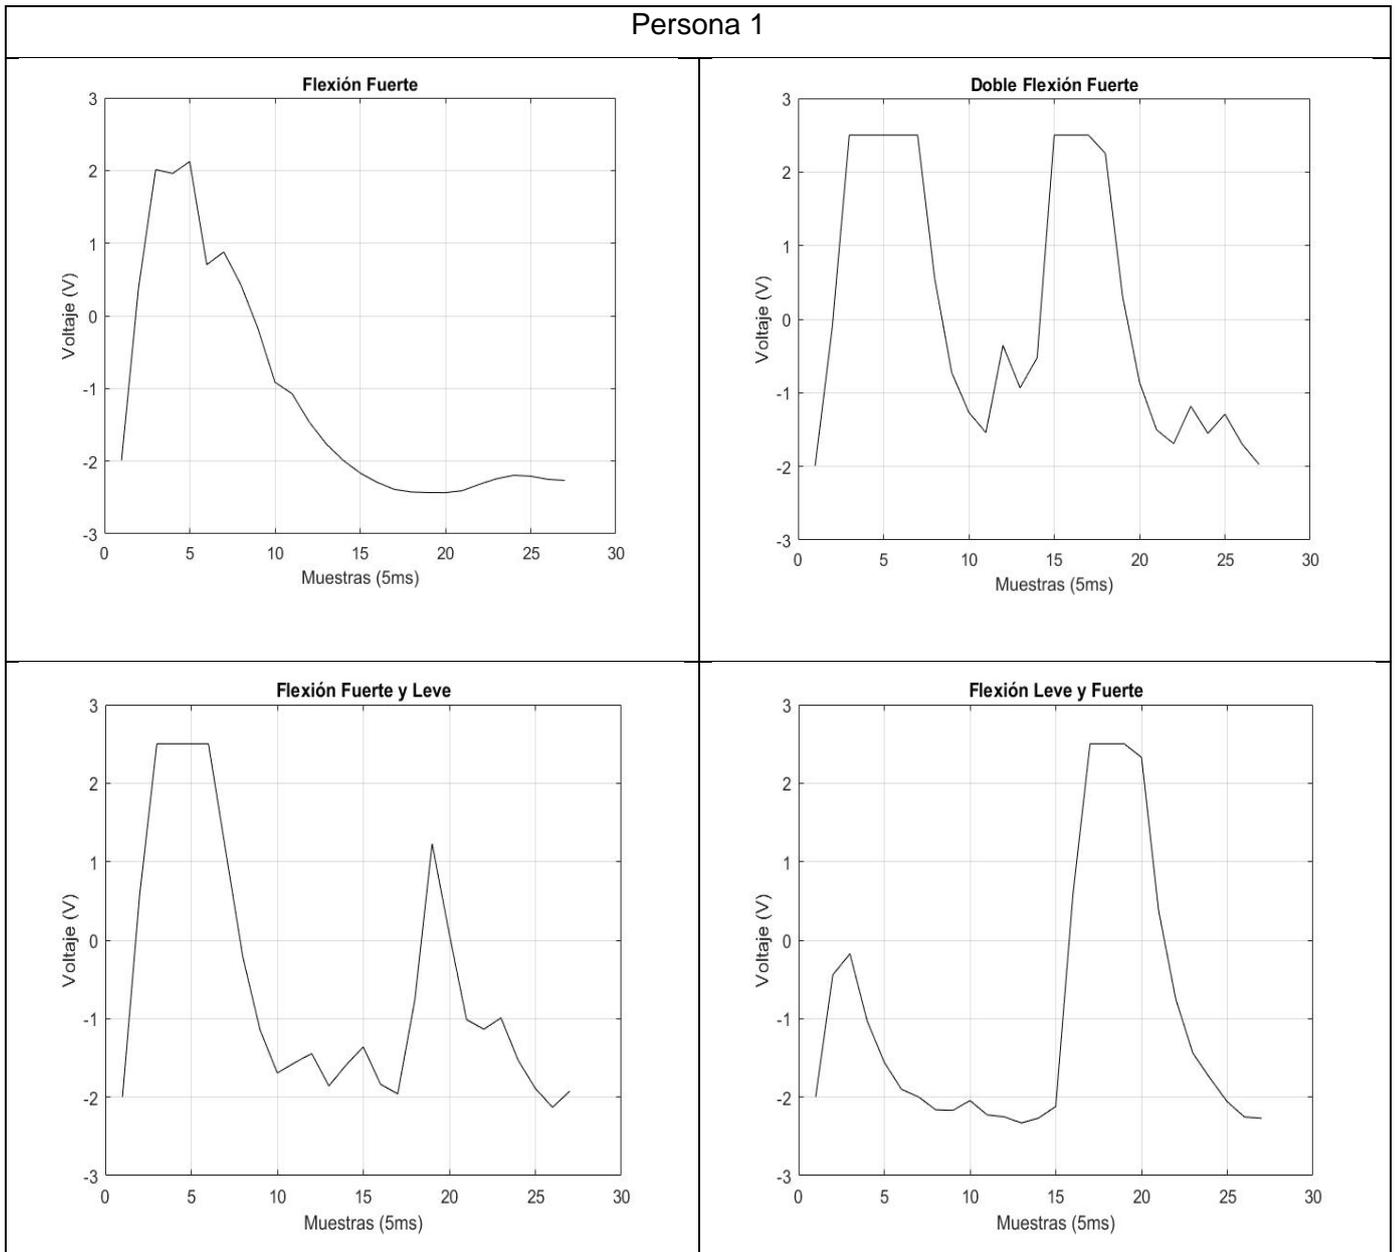
```
double Sigmoido( double num )
{
    return (double)(1.0/(1.0+exp(-num)));
}

void init(int NCap, int *TCap)
{
    n=NCap;//numero de Capas
    Tca=(int *)malloc(n*sizeof(*Tca));
    for(int i=0;i<n;i++)//se crea y almacena el número de
    { //las neuronas en cada capa
        Tca[i]=TCap[i];
    }
    sal=malloc(n*sizeof(*sal)); //Matriz de salidas
    for( int a=0;a<n;a++){
        sal[a]=malloc(Tca[a]*sizeof(*sal[a]));
    }
    Po=malloc(n*sizeof(*Po)); //matriz de pesos
    for(int i=1;i<n;i++){
        Po[i]=malloc(Tca[i]*sizeof(*Po[i]));
    }
    for(int i=1;i<n;i++){
        for(int j=0;j<Tca[i];j++){
            Po[i][j]=malloc((Tca[i-1]+1)*sizeof(*Po[i][j]));
        }
    }
    for(int i=1;i<n;i++)//se asignas los pesos entrenados
    {
        for(int j=0;j<Tca[i];j++)
        {
            for(int k=0;k<Tca[i-1]+1;k++)
            {
                Po[i][j][k]=pess[k+aux1];
            }
            aux1+=Tca[i-1]+1;
        }
    }
}

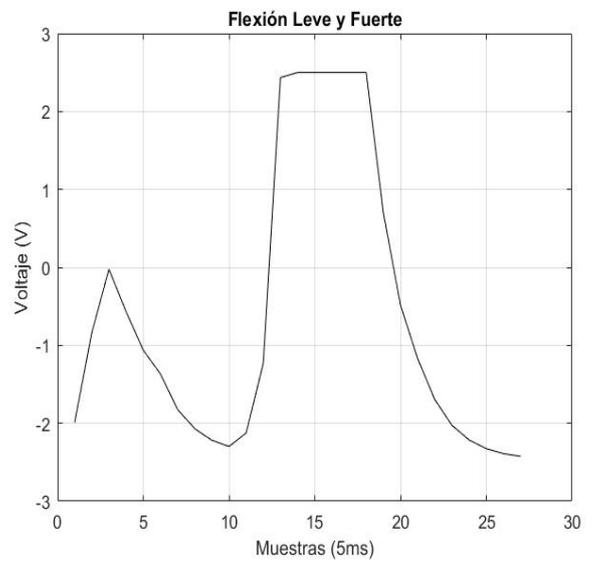
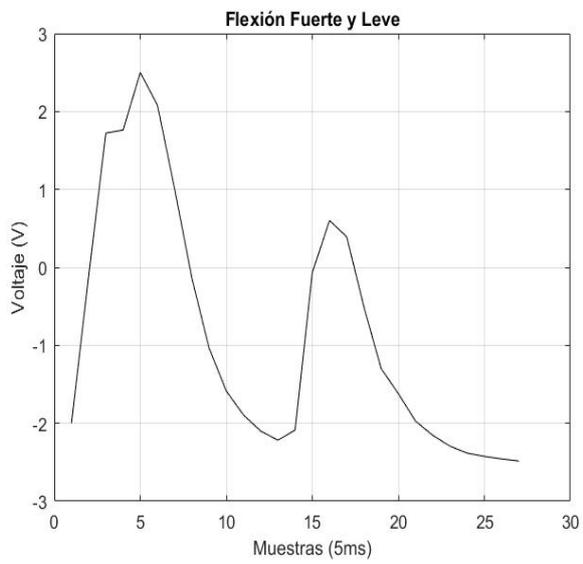
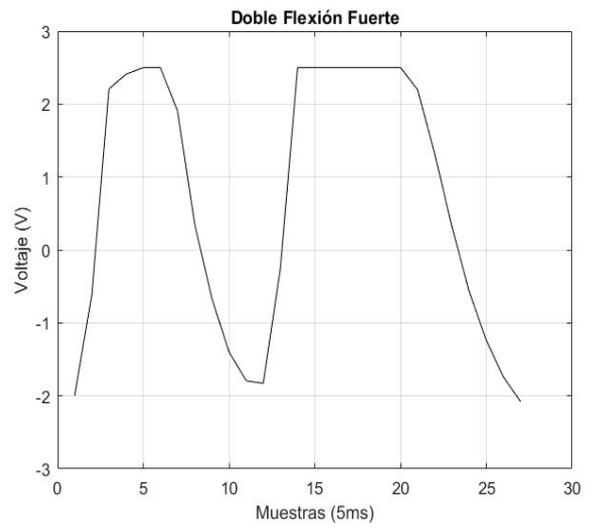
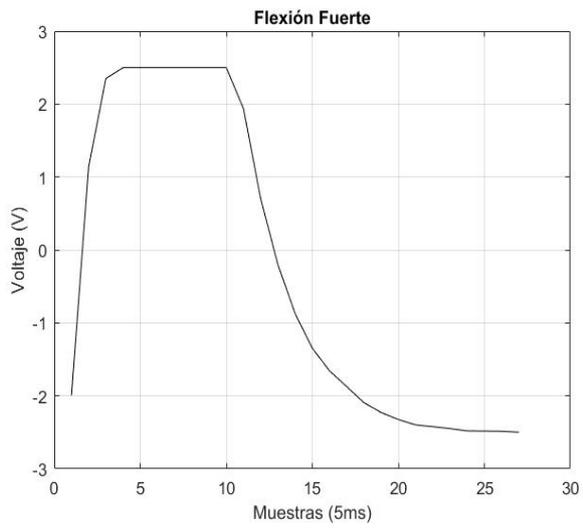
void Red(double *Ent)
{
    for(int o=0;o<Tca[0];o++){ //las salidas de la neurona j se asignan como
    sal[0][o]=Ent[o]; } // entradas para la neurona j+1
    for(int i=1;i<n;i++){
        for(int j=0;j<Tca[i];j++){
            sum1=0.0; //se suma todas las entradas
            for(int k=0;k<Tca[i-1];k++){
                sum1+= sal[i-1][k]*Po[i][j][k]; //pesos*entradas
            }
            sum1+=Po[i][j][Tca[i-1]]; //se añade el bias
            sal[i][j]=Sigmoido(sum1); //El Resultado se almacena en la matriz de
        } // salidas
    }
}
```

## ANEXO C

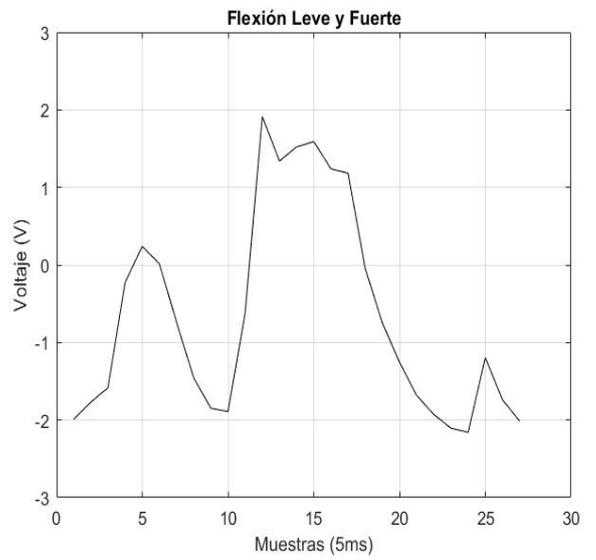
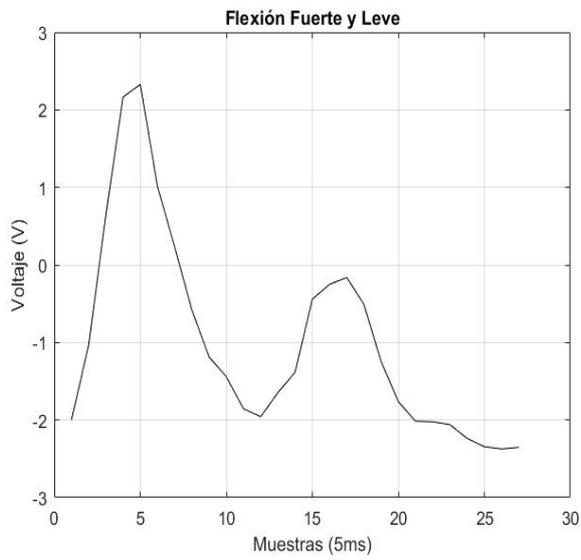
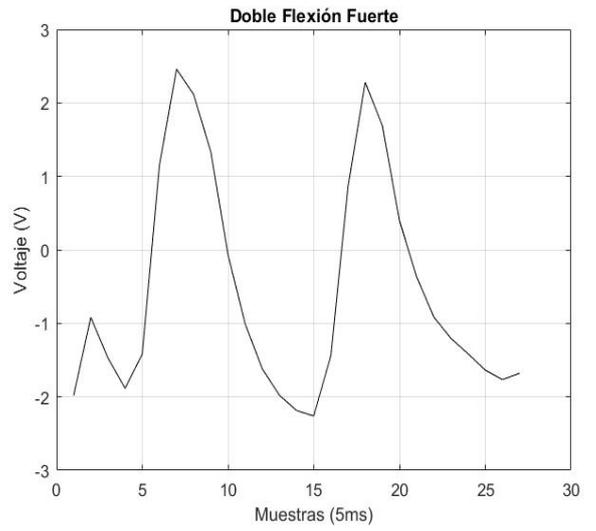
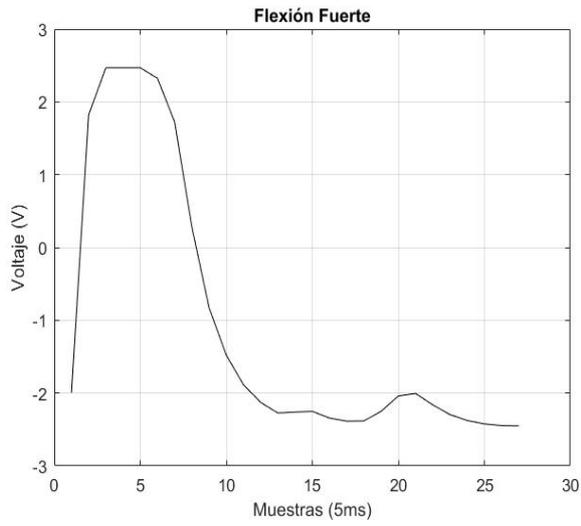
Señales EMG obtenidas en el banco de muestras



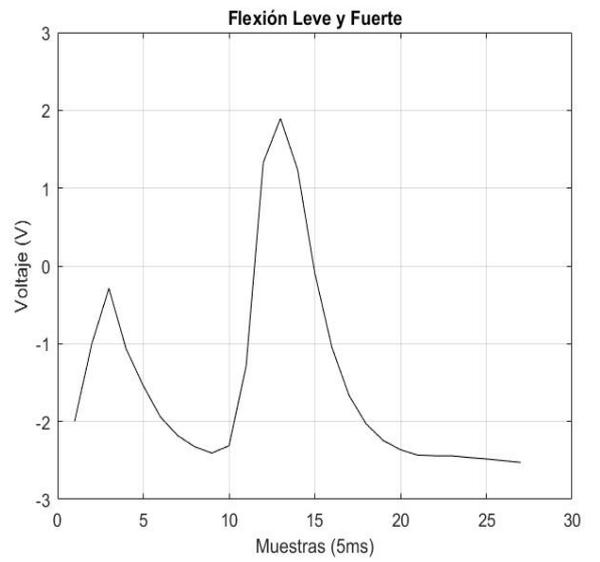
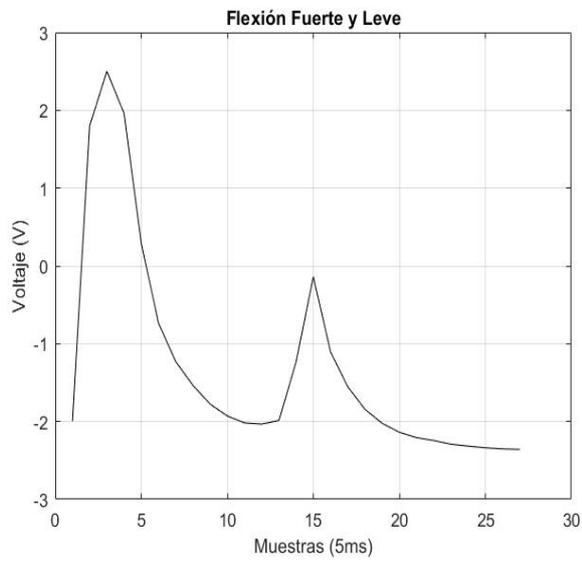
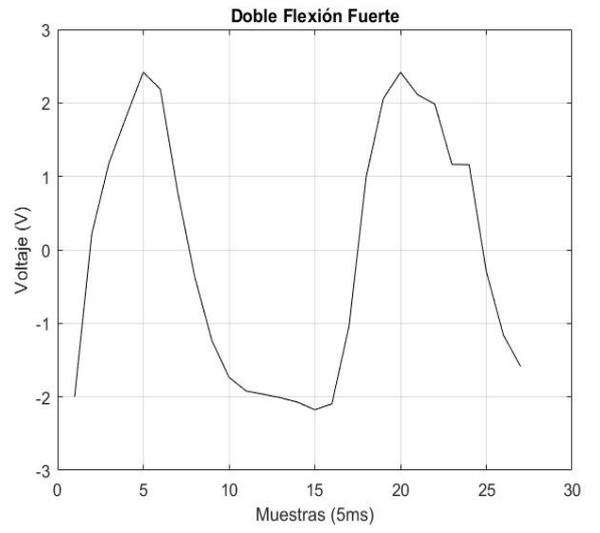
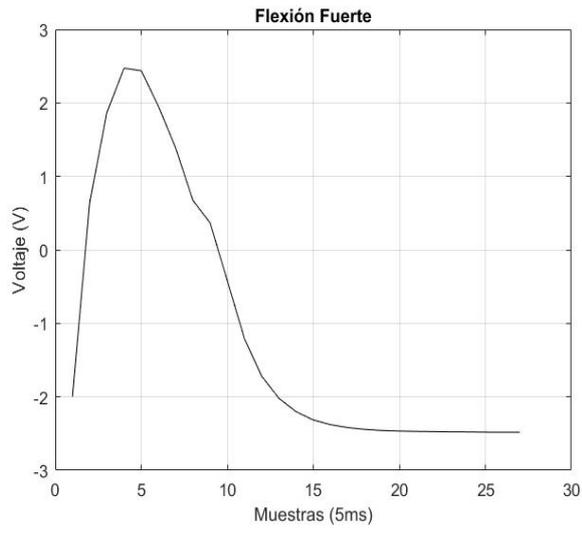
Persona 2



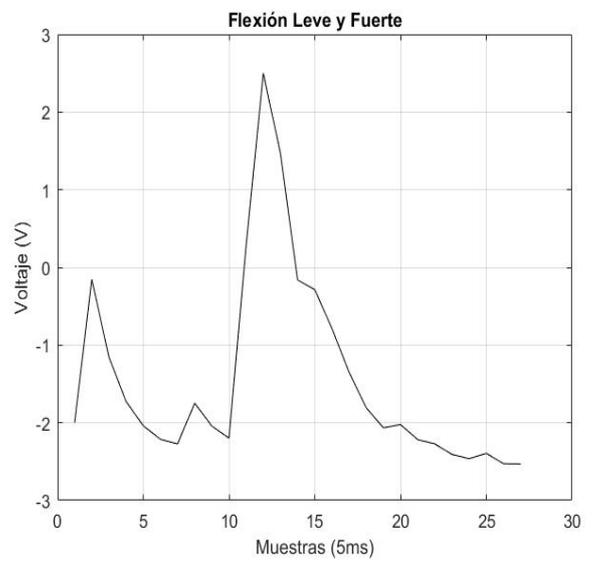
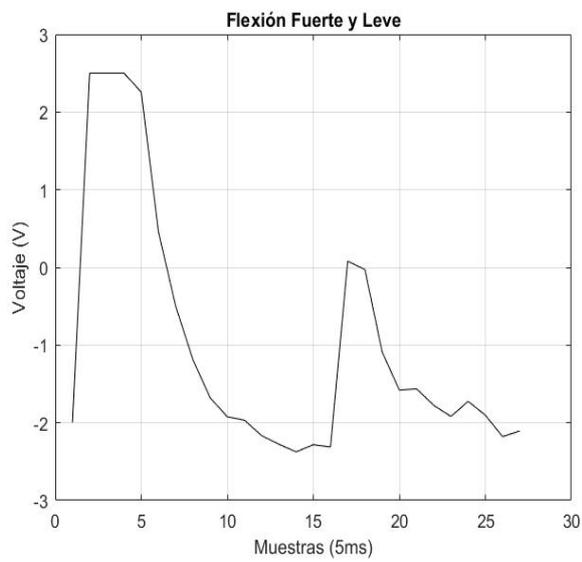
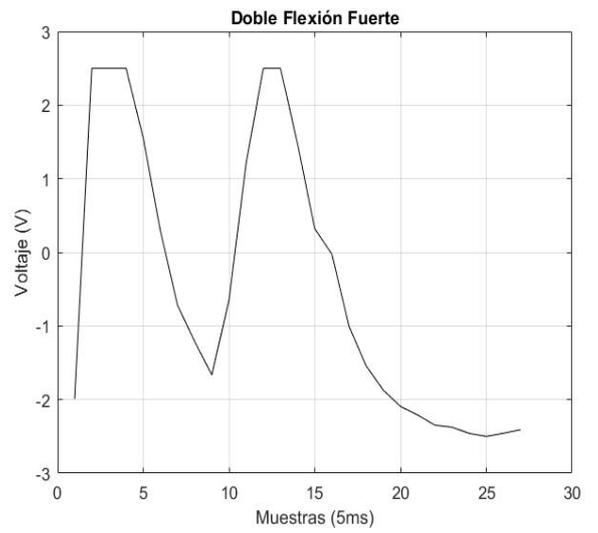
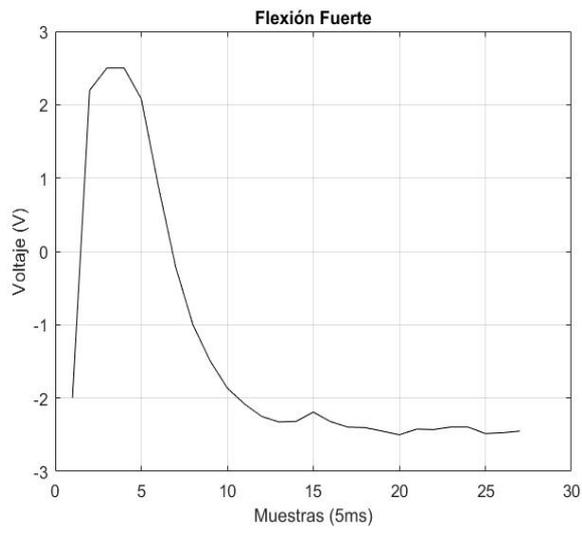
Persona 3



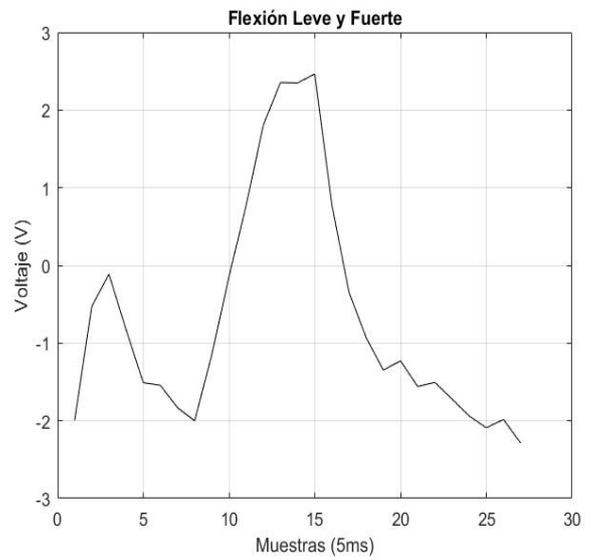
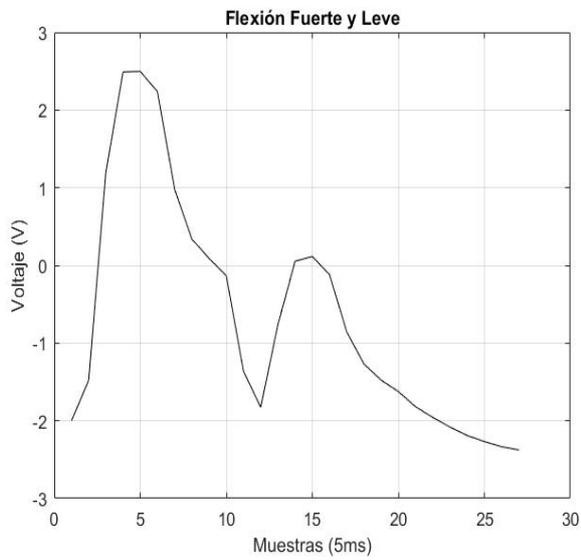
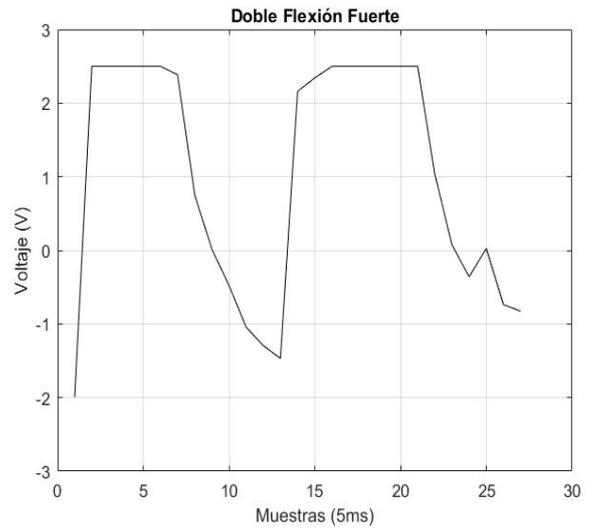
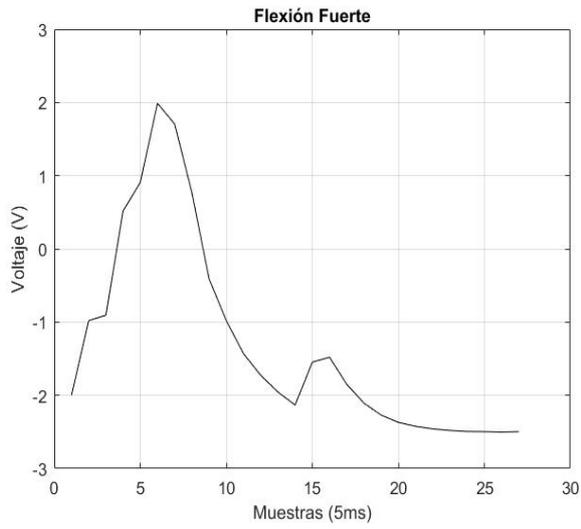
Persona 4



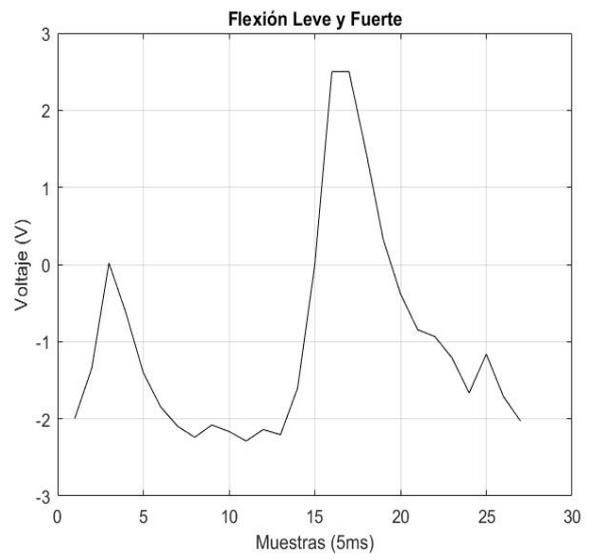
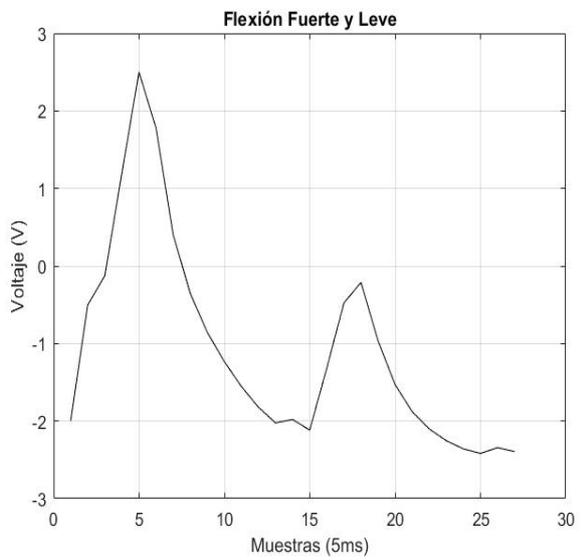
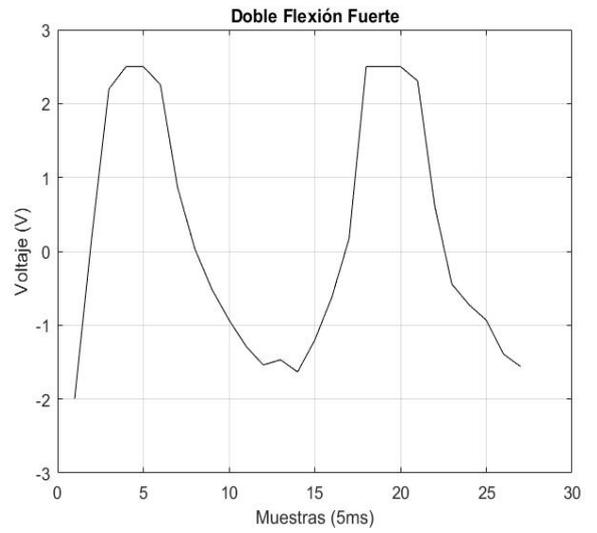
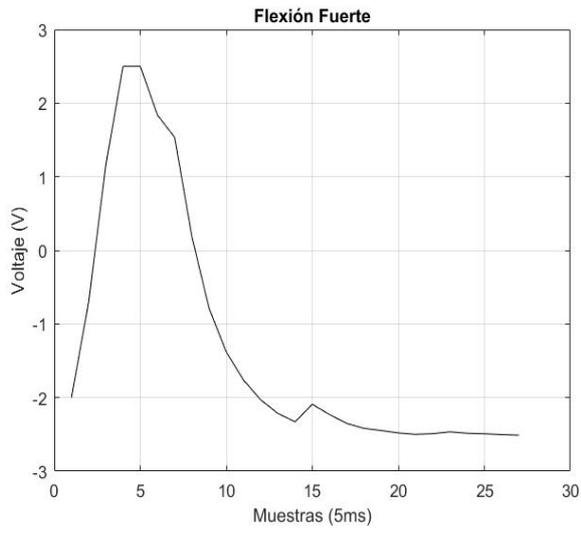
Persona 5



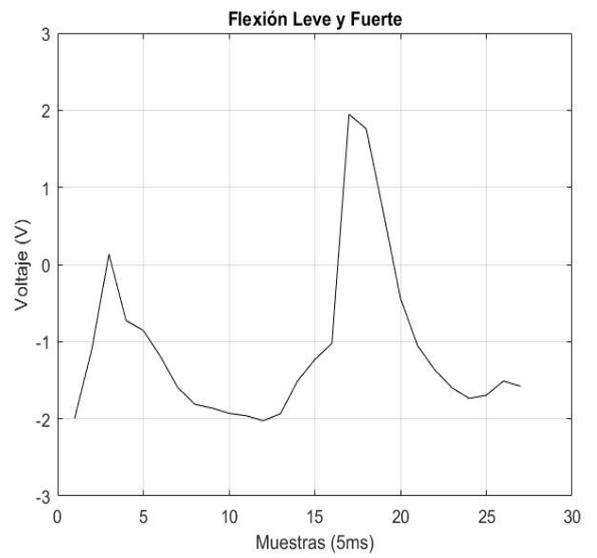
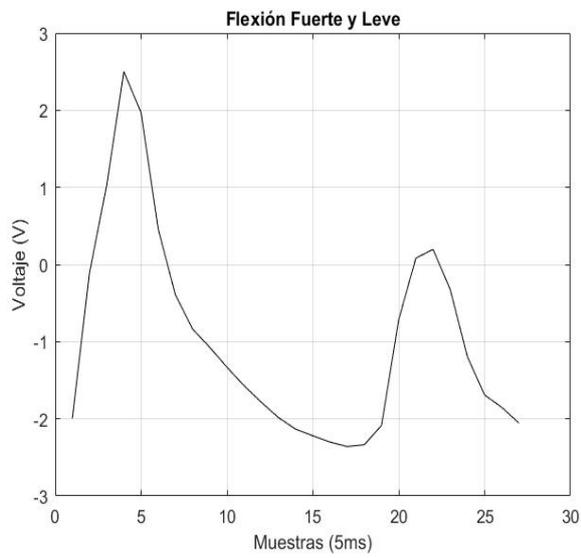
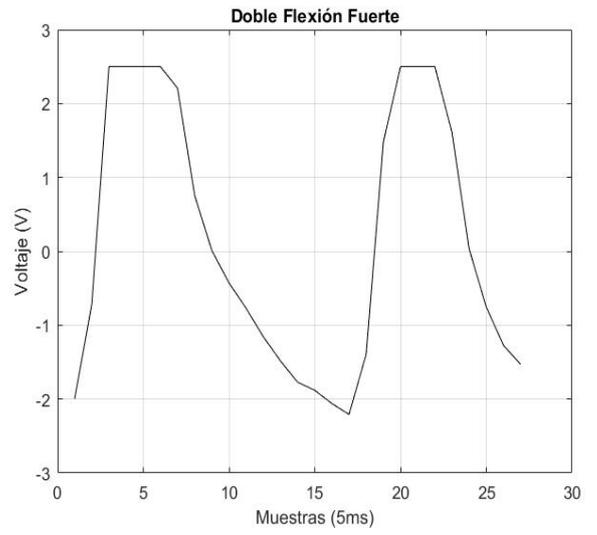
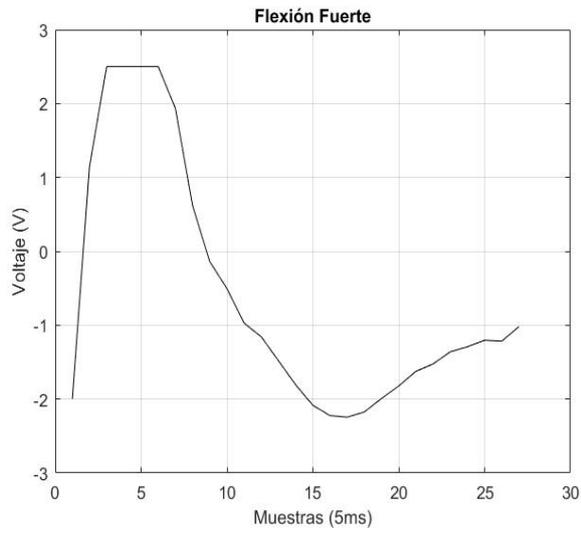
Persona 6



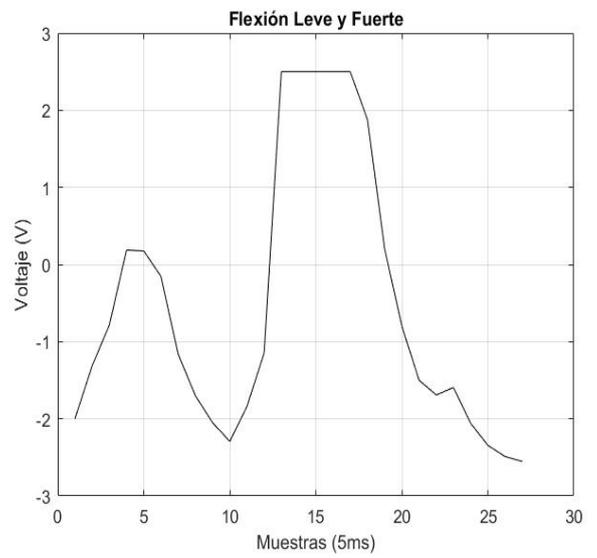
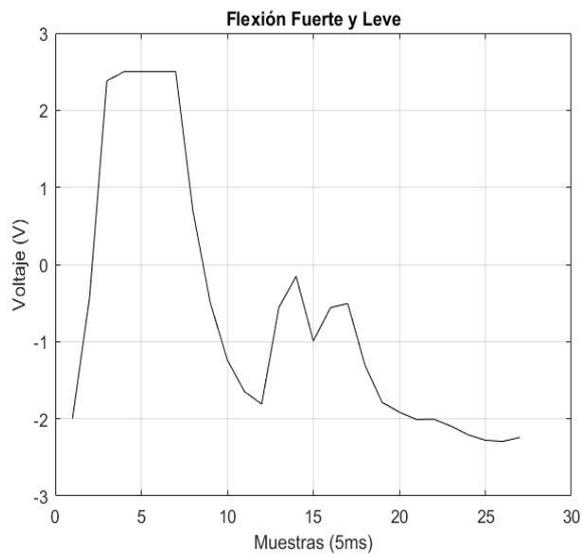
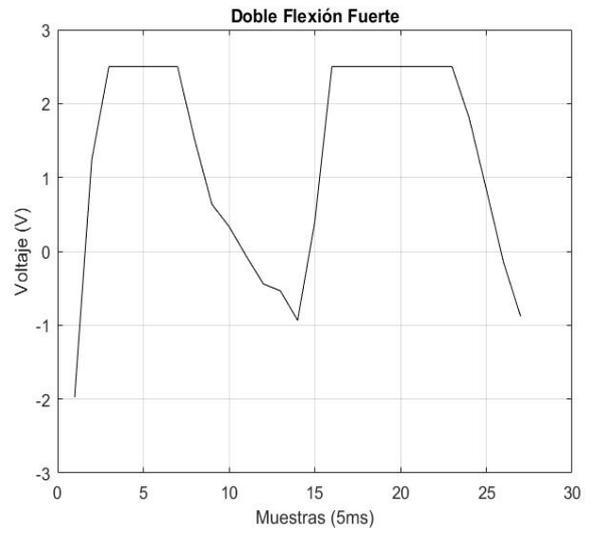
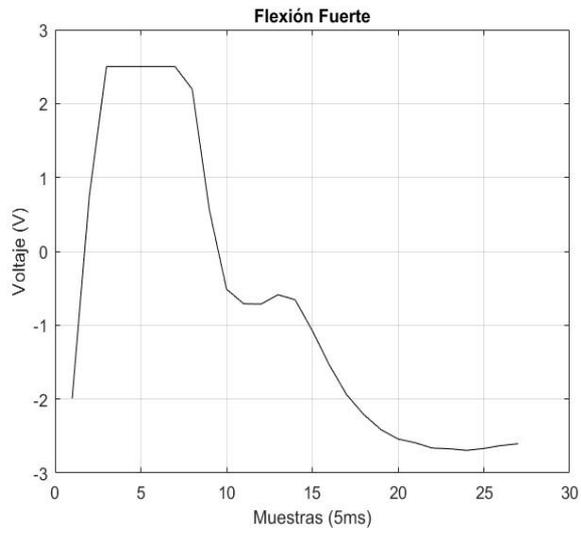
Persona 7



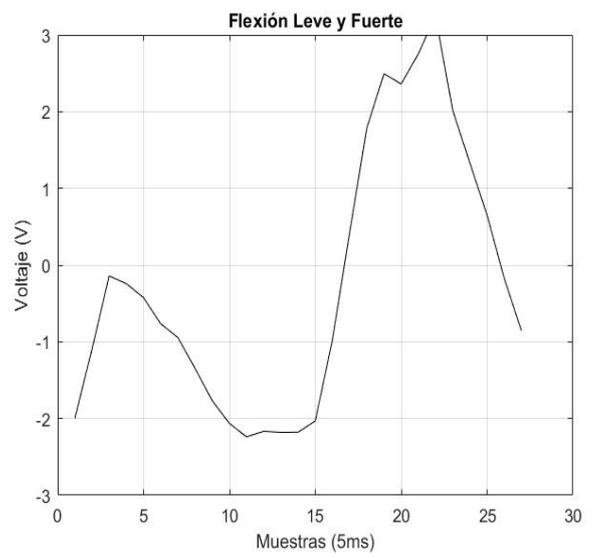
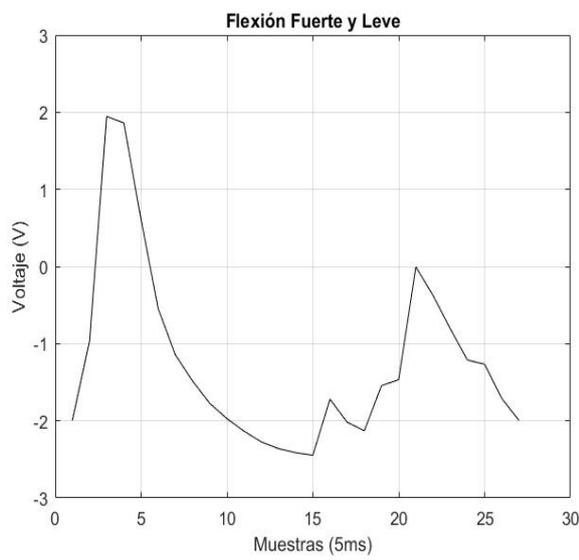
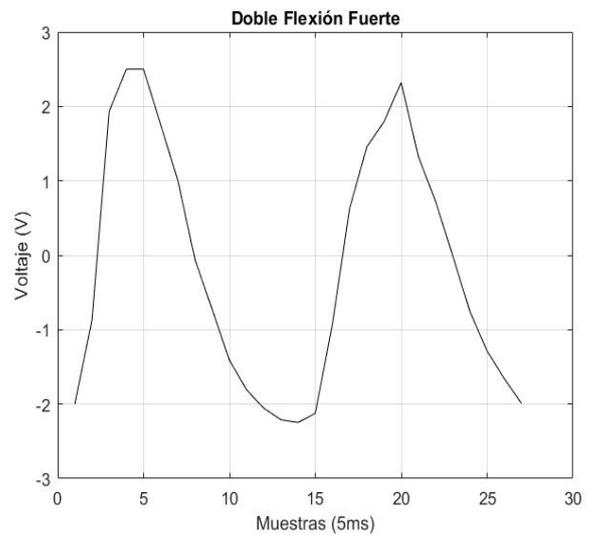
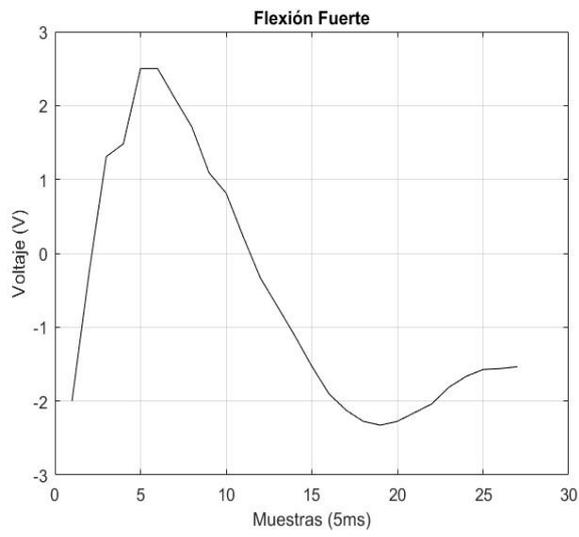
Persona 8



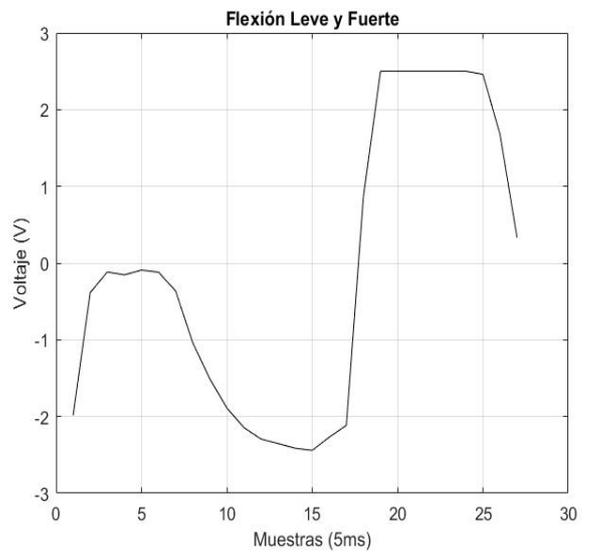
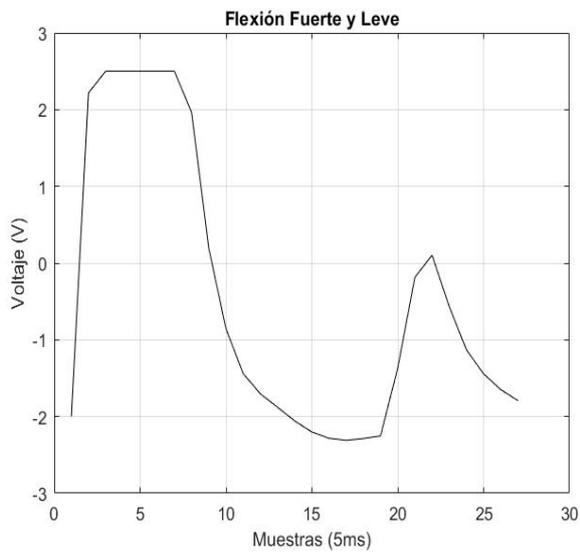
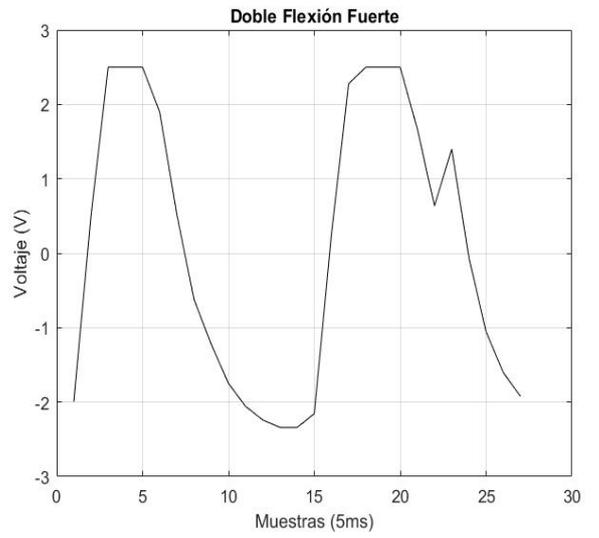
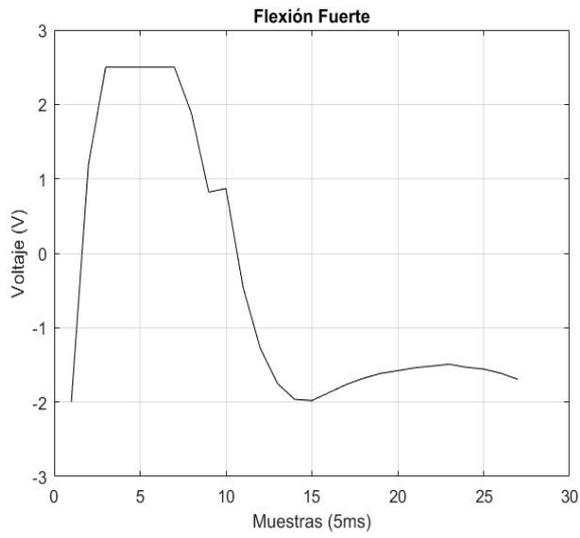
Persona 9



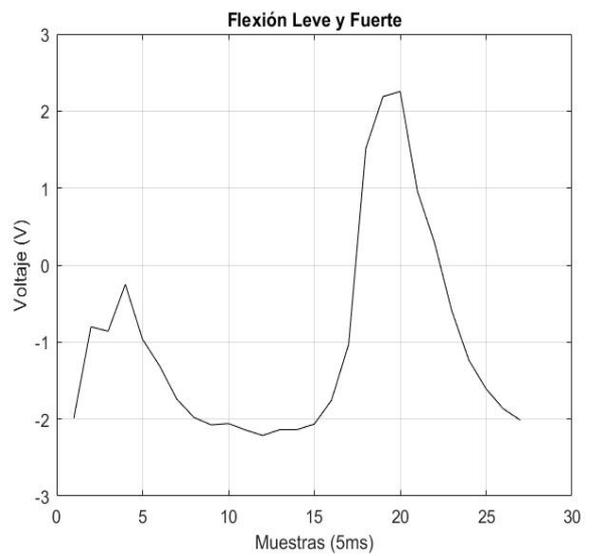
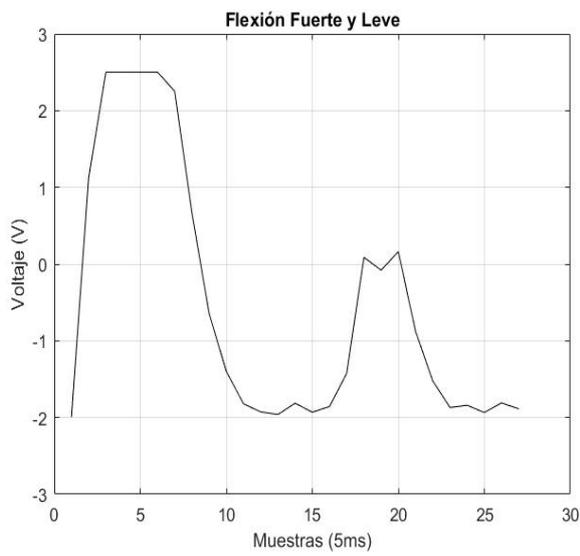
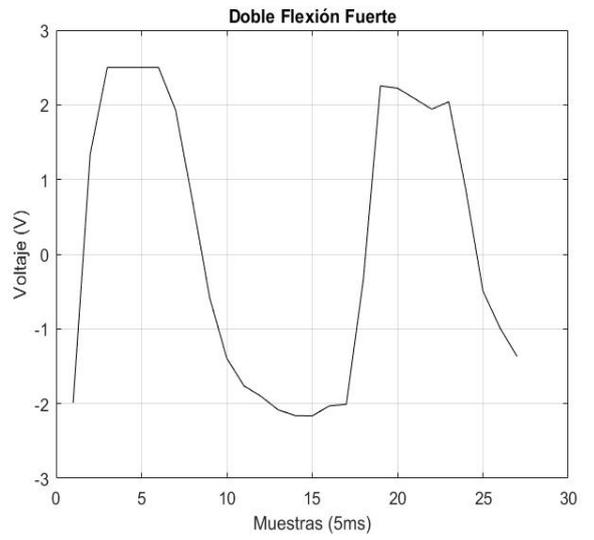
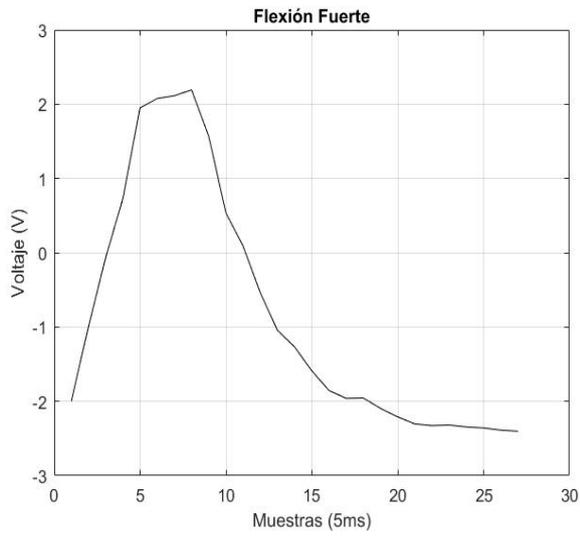
Persona 10



Persona 11



Persona 12



## ANEXO D

Tabla 1 Matriz de confusión de la prueba 1

Clase	1	2	3	4
1	100%	0	0	0
2	0	100%	0	0
3	0	0	100%	0
4	0	0	0	100%

Tabla 2 Matriz de confusión de la prueba 2

Clase	1	2	3	4
1	100%	0	0	0
2	0	100%	0	0
3	0	0	100%	0
4	0	0	0	100%

Tabla 3 Matriz de confusión de la prueba 3

Clase	1	2	3	4
1	100%	0	0	0
2	0	100%	0	0
3	0	0	66.3%	0
4	0	0	0	100%

Tabla 4 Matriz de confusión de la prueba 6

Clase	1	2	3	4
1	100%	0	0	0
2	0	100%	0	0
3	0	0	100%	0
4	0	0	0	100%

Tabla 5 Matriz de confusión de la prueba 7

Clase	1	2	3	4
1	100%	0	0	0
2	0	100%	0	0
3	0	0	100%	0
4	0	0	0	100%

Tabla 6 Matriz de confusión de la prueba 8

Clase	1	2	3	4
1	100%	0	0	0
2	0	100%	0	0
3	0	0	100%	0
4	0	0	0	100%

Tabla 7 Matriz de confusión de la prueba 9

Clase	1	2	3	4
1	100%	0	0	0
2	0	100%	0	0
3	0	0	100%	0
4	0	0	0	100%

Tabla 8 Matriz de confusión de la prueba 10

Clase	1	2	3	4
1	100%	0	0	0
2	0	100%	0	0
3	0	0	100%	0
4	0	0	0	100%

Tabla 9 Matriz de confusión de la prueba 11

Clase	1	2	3	4
1	100%	0	0	0
2	0	100%	0	0
3	0	0	100%	0
4	0	0	0	100%

Tabla 10 Matriz de confusión de la prueba 12

Clase	1	2	3	4
1	100%	0	0	0
2	0	100%	0	0
3	0	0	100%	0
4	0	0	0	100%