



**EDUCACIÓN**  
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO NACIONAL DE MÉXICO  
Instituto Tecnológico de Cd. Victoria



# Instituto Tecnológico de Ciudad Victoria

División de Estudios de Posgrado e Investigación

## TESIS

**Metodología de adquisición y clasificación de señales  
mioeléctricas para la detección de la intensidad de caminar de una  
persona con diplejía espástica**

Presentada por

**Ing. Edgar Bernardo Rios Ortega**

como requisito para la obtención del grado de  
**Maestro en Sistemas Computacionales**

Directora de tesis

**Dra. Adriana Mexicano Santoyo**

Codirector de tesis

**Dr. Said Polanco Martagón**

Cd. Victoria, Tamaulipas, diciembre 2019



"2019, Año del Caudillo del Sur, Emiliano Zapata"

## AUTORIZACIÓN DE IMPRESIÓN DE TESIS

Ciudad Victoria, Tam., a 18 / diciembre / 2019


**C. EDGAR BERNARDO RIOS ORTEGA**  
**CANDIDATO AL GRADO DE MAESTRO EN**  
**SISTEMAS COMPUTACIONALES**  
**No. de control: G-17380851**  
**PRESENTE.**


Conforme a los numerales 2.15.4 y 2.15.5 de los Lineamientos para la Operación de Estudios de Posgrado en el TecNM (ver. 2018) y por recomendación del H. Comité Tutorial, ésta división le **AUTORIZA** imprimir y reproducir digitalmente la Tesis: **"METODOLOGÍA DE ADQUISICIÓN Y CLASIFICACIÓN DE SEÑALES MIOELÉCTRICAS PARA LA DETECCIÓN DE LA INTENSIÓN DE CAMINAR DE UNA PERSONA CON DIPLEJÍA ESPÁSTICA"**, que tuvo a bien desarrollar en la División de Estudios de Posgrado e Investigación de éste instituto.

Ruego a Usted dar puntual seguimiento al formato en vigor que, para tal caso, indica las características de diseño que deberá contener tan importante documento.

### ATENTAMENTE

*Excelencia en Educación Tecnológica®*  
**VERDAD, HONESTIDAD Y SERVICIO**

  
**DR. AUSENCIO AZUARA DOMÍNGUEZ**  
**JEFE DE LA DIVISIÓN DE ESTUDIOS**  
**DE POSGRADO E INVESTIGACIÓN**

  
INSTITUTO TECNOLÓGICO  
DE CD. VICTORIA  
DEPARTAMENTO DE  
DIVISIÓN DE ESTUDIOS DE  
POSGRADO E INVESTIGACIÓN

c.c.p. Expediente





"2019, Año del Caudillo del Sur, Emiliano Zapata"

## ACEPTACIÓN DEL DOCUMENTO DE TESIS

Ciudad Victoria, Tam., a 18 / diciembre / 2019

**DR. AUSENCIO AZUARA DOMÍNGUEZ**  
**JEFE DE LA DIVISIÓN DE ESTUDIOS**  
**DE POSGRADO E INVESTIGACIÓN**  
**PRESENTE.**

**AT'N: DRA. ADRIANA MEXICANO SANTOYO**  
**PRESIDENTA DEL CONSEJO DE POSGRADO**

Los numerales 2.15.4 y 2.15.5 de los Lineamientos para la Operación de Estudios de Posgrado en el TecNM (2018), establecen los requisitos para la obtención del examen de grado de Maestro con Orientación Profesional. En tal sentido, el H. Comité Tutorial del C. **Edgar Bernardo Ríos Ortega**, estudiante del programa de Maestría en Sistemas Computacionales, con No. de control **G-17380851**, después de haber realizado la revisión del contenido y formato de la tesis: "**METODOLOGÍA DE ADQUISICIÓN Y CLASIFICACIÓN DE SEÑALES MIOELÉCTRICAS PARA LA DETECCIÓN DE LA INTENSIÓN DE CAMINAR DE UNA PERSONA CON DIPLEJÍA ESPÁSTICA**", tiene a bien emitir su **APROBACIÓN** a fin de continuar el proceso de obtención del grado académico correspondiente.

Por ese motivo se le pide a Usted, autorizar al C. **Edgar Bernardo Ríos Ortega** la impresión y reproducción electrónica de la tesis *in comento*.

**ATENTAMENTE**

*Excelencia en Educación Tecnológica®*  
**VERDAD, HONESTIDAD Y SERVICIO**



**Dra. Adriana Mexicano Santoyo**

INSTITUTO TECNOLÓGICO...  
DE CD VICTORIA  
DEPARTAMENTO DE  
DIVISIÓN DE ESTUDIOS DE  
POSGRADO E INVESTIGACIÓN

**Dr. Said Polanco Martagón**

**M.C. Osvaldo Daniel Fernández Bonilla**

**M.C. Jesús Carlos Carmona Frausto**

c.c.p. Estudiante





"2019, Año del Caudillo del Sur, Emiliano Zapata"

## CARTA DE CESIÓN DE DERECHOS

En Cd. Victoria, Tamaulipas, a 17 de Diciembre de 2019, el que suscribe, Edgar Bernardo Ríos Ortega, estudiante del programa de Maestría en Sistemas computacionales del Instituto Tecnológico de Cd. Victoria, con número de control G-17380851, manifiesto que soy autor intelectual de la presente tesis, la cual fue dirigida por la Doctora Adriana Mexicano Santoyo y el Dr. Said Polanco Martagón, cedo íntegramente los derechos del trabajo de tesis titulado Metodología de adquisición y clasificación de señales mioeléctricas para la detección de la intensidad de caminar de una persona con diplejía espástica al Tecnológico Nacional de México / Instituto Tecnológico de Cd. Victoria para su uso con fines académicos y de investigación.

Los usuarios pueden consultar y reproducir el contenido para todos los usos que tengan finalidad académica siempre y cuando sea citada la fuente de información.



---

Edgar Bernardo Ríos Ortega





"2019, Año del Caudillo del Sur, Emiliano Zapata"

## DECLARACIÓN DE ORIGINALIDAD DE LA TESIS

En Cd. Victoria, Tamaulipas, a 17 de Diciembre de 2019, el (la) que suscribe, Edgar Bernardo Ríos Ortega, estudiante del programa de Maestría en Sistemas computacionales del Instituto Tecnológico de Cd. Victoria, con número de control G-17380851. Como autor de la tesis titulada "Metodología de adquisición y clasificación de señales mioeléctricas para la detección de la intensidad de caminar de una persona con diplejía espástica", la cual fue dirigida por la Dra. Adriana Mexicano Santoyo y el Dr. Said Polanco Martagón.

Declaro que la tesis es una obra original, que es de mi autoría y que toda la información y materiales extraídos de otras fuentes han sido debidamente referenciados. Que la obra no ha sido previamente publicada y que en caso de violación de derechos de autor, me hago responsable y exonero de toda responsabilidad al Instituto Tecnológico de Cd. Victoria.

Atentamente:

  
\_\_\_\_\_  
Edgar Bernardo Ríos Ortega



## DEDICATORIA

*A mis hijos Amairani, Abiel e Ian, que siempre han sido y serán mi mayor motivación para seguir creciendo personal y profesionalmente.*

## **AGRADECIMIENTOS**

A mi esposa, por el apoyo y motivación para el desarrollo de este trabajo y también para mi vida.

A la Dra. Adriana Mexicano Santoyo, por el tiempo, dedicación y asesoramiento otorgados durante el proceso de investigación y redacción de este trabajo.

A los docentes Dr. Salvador Cervantes Álvarez, Dr. Said Polanco Martagón, M.C. Osvaldo Daniel Fernández Bonilla y M.S.I. Antonio Abrego Lerma, que gracias a su experiencia, conocimiento y motivación me orientaron en el desarrollo de la investigación, con lo cual pude lograr mi objetivo.

Al Instituto Tecnológico de Ciudad Victoria, por la oportunidad que me dio para crecer profesionalmente.

## RESUMEN

La diplegia espástica es un tipo de parálisis cerebral que afecta al control de los músculos y a la coordinación motora. Las personas con este padecimiento sufren un aumento exagerado del tono muscular, reflejos exagerados y rigidez. Los síntomas se dan sobre todo en la parte inferior del cuerpo (piernas) y afectan al movimiento, coordinación y equilibrio de la persona. De acuerdo con el último censo del INEGI, existen 1.8 millones de personas con parálisis cerebral que no tienen el control total en los movimientos del cuerpo. Actualmente, existen varios desarrollos cuya finalidad es aumentar el rango de movimiento y control de las piernas a las personas con este padecimiento. No obstante, cada caso es diferente y requiere de una solución particular.

En este documento se presenta una metodología de adquisición y clasificación de señales cuyo objetivo es identificar la intención de caminar de una persona con diplegia espástica. Para extraer las señales se creó un circuito que por medio de una tarjeta Arduino, un sensor y dos electrodos permite extraer las señales mioeléctricas del recto femoral de las piernas de una persona con diplegia espástica. La persona que proporcionó las señales presenta rigidez en los músculos de las piernas, lo que provoca que dé los pasos cortos, lentos y no doble lo suficiente la rodilla para poder dar pasos más largos y/o subir escaleras y rampas. En total se extrajo un conjunto de 1, 119, 706 señales, de cada pierna, cuando la persona estaba caminando con andador y al ejercer fuerza sobre las piernas, pero sin moverlas. Para modelar las señales se utilizó una red neuronal artificial (RNA) de 3 capas ocultas y con 80 neuronas cada una. Las señales fueron clasificadas como caminando o quieto. Con las señales extraídas se realizó el entrenamiento de la red neuronal utilizando el 80% de las señales para entrenar el modelo y 20% para realizar las pruebas. Con la finalidad de determinar el desempeño promedio del modelo, se realizó la ejecución del mismo 10 veces, en cada ejecución el conjunto de entrenamiento y prueba se generó de forma aleatoria utilizando un 80% de las señales para entrenamiento y 20% para prueba. Después de las 10 ejecuciones se obtuvo un desempeño promedio del 98% de exactitud de la RNA para la clase caminando y un 94.00% para la clase quieto. Después de validar el modelo fue almacenado y se probó con 128,212 (3 minutos aproximadamente) nuevas señales de la clase caminando y



64,731 (2 minutos aproximadamente) de la clase quieto. Al evaluar las señales se obtuvo un 98% de exactitud para la clase caminando y un 95% para la clase quieto.

Finalmente, se puede decir que la metodología es la base para diseñar y construir una órtesis robótica que ayude al paciente a caminar más rápido y doblar las rodillas para subir escalones y rampas.

## ABSTRACT

Spastic diplegia is a type of cerebral palsy that affects muscle control and motor coordination. People with this condition suffer an abnormal increase in muscle tone, exaggerated reflexes (spasticity) and joint stiffness. The symptoms occur mainly in the lower part of the body (the legs) and affect movement, coordination and the balance of a person. According to INEGI's latest census, there are around 1.8 million people with cerebral palsy who don't have total control over their body movements. At present, several developments have been made with the purpose of increasing the range of movement and the control of the legs to people with this condition. However, each case is different and requires a particular solution.

This paper presents a methodology for acquisition and classification of signals with the objective of identifying an attempt to walk of a person with spastic diplegia. For this signals extraction, a circuit has been created using an Arduino card, a sensor and two electrodes; thus allowing the extraction of myoelectric signals from the femoral rectum of the legs of a person with spastic diplegia. The person who provided these signals has stiffness in his leg muscles, causing him to take short and slow steps and not being able to bend the knee enough for taking longer steps and / or climb stairs and ramps. In total, a set of 1,119,706 signals was extracted from each leg, when the person was walking with the help of a walker and was exerting force on both his legs, but without moving them. An artificial neural network (ANN) with 3 hidden layers and 80 neurons per layer has been used for modeling these signals. Signals were classified as walking or standing. By using the extracted signals, the neural network training was carried out using 80% of the signals to train the model and 20% for testing. The model has been executed 10 times in order to determine its average performance; in the same way, the training and test set was randomly generated in each execution using 80% of the signals for training and 20% for testing. After these 10 executions, an average 98% accuracy of the RNA was obtained for the walking class and 94% for the standing class. After the validation of the model, it was stored and tested against 128,212 new signals for the walking class and 64,731 for the standing class, now obtaining a 98% of accuracy for the walking class and 95% for the standing class.

Finally, it can be concluded that the proposed methodology can be the basis for designing a robotic orthosis and its elaboration, helping the patient to walk faster and being able to bend his knees when climbing stairs and ramps.

# CONTENIDO

<b>DEDICATORIA</b> .....	<b>II</b>
<b>AGRADECIMIENTOS</b> .....	<b>III</b>
<b>RESUMEN</b> .....	<b>IV</b>
<b>ABSTRACT</b> .....	<b>VI</b>
<b>CONTENIDO</b> .....	<b>VIII</b>
<b>LISTA DE TABLAS</b> .....	<b>X</b>
<b>LISTA DE FIGURAS</b> .....	<b>XI</b>
<b>CAPÍTULO 1. INTRODUCCIÓN</b> .....	<b>1</b>
1.1. <b>DESCRIPCIÓN DEL PROBLEMA</b> .....	<b>2</b>
1.2. <b>HIPÓTESIS DE LA INVESTIGACIÓN</b> .....	<b>4</b>
1.3. <b>OBJETIVO GENERAL</b> .....	<b>4</b>
1.4. <b>OBJETIVOS ESPECÍFICOS</b> .....	<b>4</b>
1.5. <b>JUSTIFICACIÓN</b> .....	<b>5</b>
1.6. <b>ALCANCES</b> .....	<b>5</b>
1.7. <b>LIMITACIONES</b> .....	<b>6</b>
1.8. <b>ORGANIZACIÓN DEL DOCUMENTO</b> .....	<b>6</b>
<b>CAPÍTULO 2. MARCO TEÓRICO</b> .....	<b>8</b>
2.1. <b>CONCEPTOS BÁSICOS</b> .....	<b>8</b>
2.1.1 <b>DISCAPACIDADES FÍSICAS</b> .....	<b>8</b>
2.1.2 <b>DIPLEJÍA ESPÁSTICA</b> .....	<b>8</b>
2.1.3 <b>MÚSCULOS ESQUELÉTICOS</b> .....	<b>9</b>
2.1.4 <b>MÚSCULO RECTO FEMORAL</b> .....	<b>9</b>
2.1.5 <b>APRENDIZAJE MÁQUINA</b> .....	<b>10</b>
2.1.6 <b>REDES NEURONALES ARTIFICIALES</b> .....	<b>11</b>
2.1.7 <b>REDES NEURONALES CLÁSICAS</b> .....	<b>12</b>
2.1.8 <b>ELECTROMIOGRAFÍA</b> .....	<b>14</b>
2.1.9 <b>ELECTROMIOGRAFÍA SUPERFICIAL</b> .....	<b>15</b>
2.1.10 <b>ELECTRODOS</b> .....	<b>16</b>
2.1.11 <b>SENSORES MIOELÉCTRICOS</b> .....	<b>17</b>
2.1.12 <b>SEÑALES ANALÓGICAS</b> .....	<b>18</b>
2.1.13 <b>SEÑALES DIGITALES</b> .....	<b>19</b>
2.2. <b>TRABAJOS RELACIONADOS</b> .....	<b>20</b>
2.2.1 <b>IMPORTANCIA DE LA SELECCIÓN MUSCULAR PARA EL ANÁLISIS DE LA SEÑAL EMG DURANTE LA REHABILITACIÓN DEL MIEMBRO SUPERIOR DE LOS PACIENTES</b> .....	<b>20</b>
2.2.2 <b>INTERFAZ DE BIOSEÑAL PARA ROBOT DE REHABILITACIÓN DE RODILLA QUE UTILIZA SEÑALES EMG DE LOS MÚSCULOS DEL MUSLO</b> 22	
2.2.3 <b>SISTEMA DE REDES NEURONALES PARA LA IDENTIFICACIÓN EN TIEMPO REAL DE LAS SEÑALES EMG</b> .....	<b>23</b>
2.2.4 <b>CLASIFICACIÓN DE EMG A TRAVÉS DE ÍNDICES LINEALES Y NO LINEALES POR MEDIO DE REDES NEURONALES ARTIFICIALES</b> .25	
2.2.5 <b>RECONOCIMIENTO DE PATRONES DE LAS SEÑALES EMG POR REDES NEURONALES</b> .....	<b>26</b>

2.2.6	DETECCIÓN DE LA INTENCIÓN DE MOVIMIENTO A PARTIR DE SEÑALES ELECTROMIOGRÁFICAS UTILIZANDO REDES NEURONALES 27	
2.2.7	ADQUISICIÓN Y PROCESAMIENTO DE SEÑALES EMG PARA CONTROLAR MOVIMIENTO DE UN BRAZO HIDRÁULICO .....	31
2.2.8	UN ENFOQUE DE APRENDIZAJE PROFUNDO PARA LA CLASIFICACIÓN BASADA EN EMG DE FASES DE LA MARCHA DURANTE LA MARCHA A NIVEL DEL SUELO .....	32
2.2.9	TABLA COMPARATIVA DE TRABAJOS RELACIONADOS .....	33
<b>CAPÍTULO 3. METODOLOGÍA PARA LA ADQUISICIÓN Y CLASIFICACIÓN DE SEÑALES MIOELÉCTRICAS .....</b>		<b>36</b>
3.1.	<b>METODOLOGÍA GENERAL.....</b>	<b>37</b>
3.2.	<b>SELECCIÓN DE DISPOSITIVOS PARA EXTRACCIÓN DE SEÑALES .....</b>	<b>38</b>
3.3.	<b>IDENTIFICACIÓN DEL MÚSCULO .....</b>	<b>39</b>
3.4.	<b>EXTRACCIÓN DE SEÑALES CONVERSIÓN ANALÓGICO DIGITAL .....</b>	<b>41</b>
3.5.	<b>MUESTREO Y CLASIFICACIÓN DE SEÑALES.....</b>	<b>42</b>
3.6.	<b>ANÁLISIS DE SEÑALES.....</b>	<b>45</b>
3.7.	<b>ESTUDIO DE LA BIOMECÁNICA DE LA MARCHA.....</b>	<b>48</b>
3.8.	<b>MODELADO CON UNA RED NEURONAL ARTIFICIAL.....</b>	<b>48</b>
3.8.1	ENTRENAMIENTO DE RED NEURONAL ARTIFICIAL.....	50
3.8.2	ALMACENAMIENTO DEL MODELO .....	52
<b>CAPÍTULO 4. RESULTADOS EXPERIMENTALES .....</b>		<b>53</b>
4.1.	<b>SELECCIÓN DE DISPOSITIVOS PARA EXTRACCIÓN DE SEÑALES .....</b>	<b>53</b>
4.2.	<b>IDENTIFICACIÓN DEL MÚSCULO .....</b>	<b>53</b>
4.3.	<b>EXTRACCIÓN DE SEÑALES CONVERSIÓN ANALÓGICO - DIGITAL .....</b>	<b>54</b>
4.4.	<b>MUESTREO Y CLASIFICACIÓN DE SEÑALES.....</b>	<b>54</b>
4.5.	<b>ANÁLISIS DE SEÑALES.....</b>	<b>54</b>
4.5.1	ESTAR QUIETO.....	54
4.5.2	CAMINANDO.....	55
4.6.	<b>BIOMECÁNICA DE LA MARCHA.....</b>	<b>58</b>
4.7.	<b>MODELADO CON UNA RED NEURONAL ARTIFICIAL.....</b>	<b>58</b>
4.7.1	EVALUACIÓN DEL MODELO .....	62
<b>CAPÍTULO 5. CONCLUSIONES Y TRABAJO FUTURO .....</b>		<b>64</b>
5.1.	<b>CONCLUSIONES .....</b>	<b>64</b>
5.2.	<b>TRABAJOS FUTUROS.....</b>	<b>66</b>
<b>REFERENCIAS BIBLIOGRÁFICAS .....</b>		<b>67</b>

## LISTA DE TABLAS

TABLA 1 MÚSCULOS ORDENADOS POR SU CONTRIBUCIÓN AL MOVIMIENTO EVALUADO [23] .....	21
TABLA 2 CLASIFICACIÓN DE ESTADOS ESTACIONARIOS Y TRANSITORIOS [28] .....	29
TABLA 3 RESULTADOS OBTENIDOS EN LAS DIFERENTES PRUEBAS CON DATOS DE ENTRENAMIENTO Y DATOS DESCONOCIDOS [28] .....	30
TABLA 4 RESULTADOS OBTENIDOS EN LAS DIFERENTES PRUEBAS CON DATOS DE ENTRENAMIENTO Y DATOS DESCONOCIDOS [28] .....	30
TABLA 5 CLASIFICACIÓN CORRECTA PARA LAS DIFERENTES TÉCNICAS DE EXTRACCIÓN DE PATRONES [29] .....	32
TABLA 6 ESTADO DEL ARTE .....	34
TABLA 7 ESPECIFICACIONES ELÉCTRICAS DEL SENSOR MIOELÉCTRICO MYOWARE .....	39
TABLA 8 ENTRENAMIENTO DE LA RED NEURONAL CON 3 CAPAS OCULTAS DE 80 NEURONAS CADA UNA .....	59
TABLA 9 ENTRENAMIENTO DE LA RED NEURONAL CON UNA CAPA OCULTAS DE 80 NEURONAS .....	60
TABLA 10 ENTRENAMIENTO DE LA RED NEURONAL CON 2 CAPAS OCULTAS DE 50 NEURONAS CADA UNA .....	60
TABLA 11 ENTRENAMIENTO DE LA RED NEURONAL CON 3 CAPAS OCULTAS DE 80 NEURONAS CADA UNA, CON MATRIZ DE ENTRADA MODIFICADA .....	61

## LISTA DE FIGURAS

FIGURA 1 SEÑALES EMG CUANDO CAMINA EN LÍNEA RECTA (LÍNEA NARANJA PIERNA DERECHA Y LÍNEA AZUL PIERNA IZQUIERDA) .....	3
FIGURA 2 SEÑALES EMG CUANDO SE MANTIENE PARADO (LÍNEA NARANJA PIERNA DERECHA Y LÍNEA AZUL PIERNA IZQUIERDA) .....	3
FIGURA 3 SEÑALES EMG CUANDO CAMINA EN CÍRCULOS (LÍNEA NARANJA PIERNA DERECHA Y LÍNEA AZUL PIERNA IZQUIERDA) .....	3
FIGURA 4 SEÑALES EMG CUANDO CAMINA CANSADO (LÍNEA NARANJA PIERNA DERECHA Y LÍNEA AZUL PIERNA IZQUIERDA) .....	3
FIGURA 5 POSICIONES ANATÓMICAS PARA COLOCAR LOS ELECTRODOS SUPERFICIALES [10]. .....	10
FIGURA 6 A) MODELO DE LA NEURONA BIOLÓGICA, B) MODELO MATEMÁTICO DE LA NEURONA ARTIFICIAL [11] .....	12
FIGURA 7 ARQUITECTURA DE UNA RED NEURONAL CLÁSICA [12] .....	14
FIGURA 8 ELECTRODOS SUPERFICIALES [17] .....	16
FIGURA 9 SENSOR MUSCULAR MYOWARE [20] .....	17
FIGURA 10 SEÑALES ANALÓGICAS [21] .....	18
FIGURA 11 SEÑALES DIGITALES [21] .....	19
FIGURA 12 SISTEMA DE TAREAS [23] .....	21
FIGURA 13 ROBOT DE REHABILITACIÓN DE RODILLA [24].....	23
FIGURA 14 ARQUITECTURA SOFTWARE DEL SISTEMA DE RECONOCIMIENTO DE PATRONES [25] .....	24
FIGURA 15 COLOCACIÓN BIPOLAR DE ELECTRODOS (A) DEL MÚSCULO FLEXOR Y (B) DEL MÚSCULO EXTENSOR [26].....	25
FIGURA 16 ESQUEMA DE RED NEURONAL APLICADA AL SISTEMA [28] .....	29
FIGURA 17 DIAGRAMA DEL AUTÓMATA DE ESTADOS [25] .....	29
FIGURA 18 ESTRUCTURA DE LOS VECTORES ENTRADA A LAS REDES NEURONALES ARTIFICIALES [30] .....	33
FIGURA 19 ARQUITECTURA GENERAL DEL PROYECTO .....	37
FIGURA 20 SENSOR MÚSCULAR MYOWARE .....	38
FIGURA 21 UBICACIÓN Y CONEXIÓN DE LOS SENSORES .....	40
FIGURA 22 ARDUINO NANO [22] .....	41
FIGURA 23 CONEXIONES ARDUINO, SENSORES MYOWARE, BLUETOOTH Y MICROSD .....	42
FIGURA 24 COLOCACIÓN DE LOS ELECTRODOS Y EL SENSOR MYOWARE .....	42
FIGURA 25 LECTOR DE MEMORIA MICROSD [36] .....	43
FIGURA 26 MÓDULO BLUETOOTH HC-06 [47] .....	43
FIGURA 27 INTERFAZ DE PROGRAMA ANDANDO.PY .....	44
FIGURA 28 ARCHIVO TEXTO CON VALORES DE LAS SEÑALES .....	45
FIGURA 29 SEÑALES EMG CUANDO ESTÁ QUIETO .....	46
FIGURA 30 SEÑALES EMG CUANDO ESTÁ CAMINANDO EN LÍNEA RECTA.....	46
FIGURA 31 SEÑALES EMG CUANDO ESTÁ CAMINANDO EN CÍRCULOS.....	47
FIGURA 32 SEÑALES EMG CUANDO ESTÁ CAMINANDO CANSADO.....	47
FIGURA 33 REPRESENTACIÓN DE LOS PRINCIPALES COMPONENTES DE LA MARCHA .....	48
FIGURA 34 MATRIZ DE MUESTRAS Y ETIQUETAS PARA EL ENTRENAMIENTO DE LA RED NEURONAL .....	49
FIGURA 35 MATRIZ DE CONFUSIÓN PARA UN PROBLEMA DE CLASIFICACIÓN BINARIA .....	51
FIGURA 36 MATRIZ DE CONFUSIÓN DE LA RED NEURONAL .....	52
FIGURA 37 GRÁFICA SEÑALES EMG QUIETO .....	55
FIGURA 38 SEÑALES EMG CAMINANDO EN LÍNEA RECTA.....	56
FIGURA 39 SEÑALES EMG CAMINANDO EN CÍRCULOS .....	57
FIGURA 40 SEÑALES EMG CAMINANDO CANSADO .....	58
FIGURA 41 MATRIZ DE CONFUSIÓN DE LA RED NEURONAL .....	59
FIGURA 42 EJEMPLO MATRIZ DE ENTRADA SIN LAS COLUMNAS NONES .....	61
FIGURA 43 MATRIZ DE CONFUSIÓN DE LA RED NEURONAL DESPUÉS DEL ENTRENAMIENTO .....	63

# CAPÍTULO 1

## INTRODUCCIÓN

---

El sistema muscular, es un sistema de tejidos que abarca todo el cuerpo, y que con la colaboración del sistema nervioso y del sistema óseo, produce los movimientos del cuerpo en una forma útil y coordinada. El sistema permite que la persona se mueva de un lugar a otro y realice diversas funciones de movimiento de acuerdo con los deseos y necesidades de cada una [1]. Sin embargo, muchas personas tienen dificultades para realizar ciertas actividades. En 2014, residían en México aproximadamente 7.1 millones de personas con alguna discapacidad, de estos el 64.1% tiene la dificultad para caminar, subir o bajar usando sus piernas. Las principales causas de esta discapacidad fueron por enfermedad, vejez y por nacimiento [2]. De acuerdo con el censo del año 2014 del INEGI existen 1.8 millones de personas con parálisis cerebral que no tienen el control total en los movimientos del cuerpo.

En este sentido la electromiografía (EMG) es un método de examen neurológico que permite la observación y el registro de actividades eléctricas que se producen mediante la contracción del tejido muscular y nervioso. Gracias a este método, muchas enfermedades del sistema nervioso que se producen en los músculos (trastornos en la marcha como la diplejía espástica) se pueden diagnosticar con precisión [3]. El movimiento de las piernas al caminar implica que se envíen diferentes impulsos eléctricos por los nervios hacia los músculos, para cada acción a realizar. Estos impulsos pueden ser adquiridos como señales por electrodos y analizados para determinar si contienen patrones que indiquen cuál es el movimiento que se realizó.

En la actualidad, investigadores de muchas disciplinas han diseñado redes neuronales artificiales (Artificial Neural Networks - ANN) para resolver una variedad



de problemas en reconocimiento de patrones, predicción, optimización, memoria asociativa y control [4]. De acuerdo con Zhen Zhang [5], las ANN se pueden utilizar para detectar la intención de movimiento por medio de la interpretación de las señales mioeléctricas.

En la investigación descrita en este documento se propone la caracterización de las señales mioeléctricas extraídas del músculo de la pierna de una persona con diplejía con la finalidad de analizarlas y caracterizarlas hasta extraer patrones para crear un modelo que permita identificar la intención de caminar de la persona con diplejía espástica.

### **1.1. DESCRIPCIÓN DEL PROBLEMA**

Las personas con discapacidad física como la diplejía espástica en las partes inferiores del cuerpo encuentran dificultad para controlar algunos o todos sus músculos ya que tienden a estirarse y debilitarse [6]. Cuando la persona objeto de estudio intenta caminar, levanta la pierna e intenta doblar la rodilla, ésta pierde el equilibrio y cruza los pies debido a lo rígido de los músculos.

Identificar la intención de caminar de la persona con diplejía no es tarea sencilla ya que es necesario determinar con algún método inteligente si la persona en realidad quiere caminar o sólo mantener el equilibrio mientras está parado, apoyándose con el andador. Razón por la que se requiere la adquisición y clasificación de señales mioeléctricas para identificar la intención de caminar.

De acuerdo con [5] las señales mioeléctricas se producen en el músculo al realizar un movimiento voluntario o involuntario, cuando la persona con diplejía se mantiene parada está generando señales por lo tenso de sus músculos y por la fuerza que aplica para mantener el equilibrio, cuando quiere iniciar la marcha, lo cual hace difícil

encontrar los patrones de las señales mioeléctricas que indiquen que la persona realmente está caminando o tiene la intención de hacerlo.

En la Figura 1 se muestra una gráfica con las señales EMG que se producen cuando la persona camina en línea recta, cada línea representa los valores de la fuerza que aplica en cada pierna. El paso con la pierna derecha que se representa con la línea naranja aplica una fuerza en la pierna para subirla y avanza el pie, después baja la pierna derecha y aplica una fuerza en la pierna izquierda que se representa con la línea azul, para subirla y avanzar, y así sucesivamente.

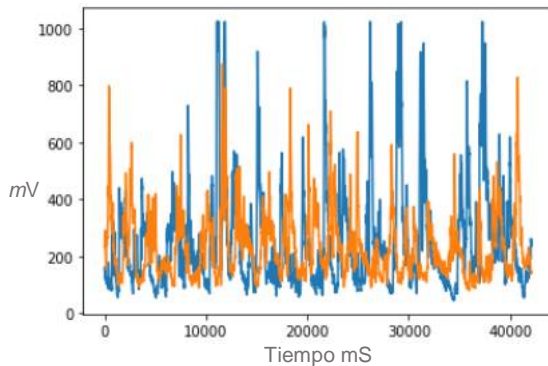


Figura 1 Señales EMG Cuando camina en línea recta (Línea naranja pierna derecha y línea azul pierna izquierda)

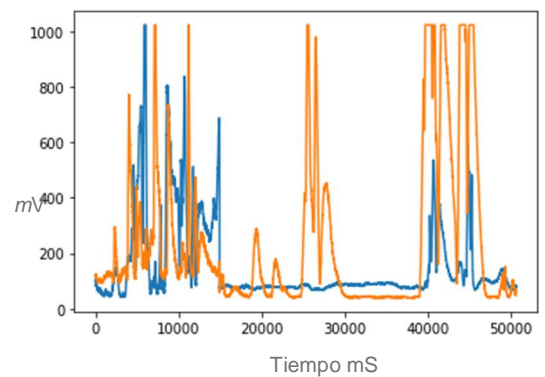


Figura 2 Señales EMG Cuando se mantiene parado (Línea naranja pierna derecha y línea azul pierna izquierda)




Figura 3 Señales EMG Cuando camina en círculos (Línea naranja pierna derecha y línea azul pierna izquierda)




Figura 4 Señales EMG Cuando camina cansado (Línea naranja pierna derecha y línea azul pierna izquierda)

En la Figura 2, se muestran las señales EMG cuando está parado, quieto con el andador, Figura 3, se muestran las señales EMG cuando camina en círculos y la Figura 4 cuando camina y ya está cansado. Como se puede observar en las gráficas las señales varían dependiendo de la condición física de la persona, dependiendo si está parado caminando en línea recta o caminando en círculos.

## **1.2. HIPÓTESIS DE LA INVESTIGACIÓN**

El desarrollo de una metodología de adquisición y clasificación de señales mioeléctricas que permita identificar la intención de caminar de una persona con diplejía espástica sentará la base para el desarrollo de un dispositivo que permita auxiliar en el andar de la persona.

## **1.3. OBJETIVO GENERAL**

Desarrollar una metodología que permita adquirir y clasificar señales mioeléctricas extraídas del recto femoral de una persona con diplejía espástica para identificar su intención de caminar.

## **1.4. OBJETIVOS ESPECÍFICOS**

Para alcanzar el objetivo general se determinaron los siguientes objetivos específicos:

- Seleccionar los dispositivos electrónicos y el software a utilizar para extraer las señales.
- Identificar los músculos a utilizar para adquirir las señales.
- Adquirir señales mioeléctricas del musculo recto femoral de las dos piernas de la persona con diplejía cuando está parado y cuando está caminando.

- Analizar y graficar las señales mioeléctricas para determinar el tiempo de muestreo de las señales que debe ser utilizado como entrada a la red neuronal.
- Clasificar la señal utilizando técnicas de aprendizaje supervisado, en particular redes neuronales artificiales.

## **1.5. JUSTIFICACIÓN**

El análisis de la señal eléctrica de los músculos ha sido abordado en una variedad de estudios con la finalidad de extraer características, modelar la señal y reconocer patrones [6]. De esta forma diferenciar entre varios estados del músculo, así como la diferenciación entre tipos de movimientos. Sin embargo, identificar la intención de caminar de una persona con diplejía espástica es una tarea compleja, ya que la mayoría de los músculos de sus piernas se encuentran tensos. El desarrollo de una metodología de adquisición de señales y su clasificación permitirán una estimación apropiada de la intención de caminar y servirán de base para el desarrollo de una órtesis robótica.

## **1.6. ALCANCES**

En este trabajo se realizó el muestreo de señales a una persona con diplejía espástica que no tiene equilibrio sin el uso de un andador y que por tanto no puede andar sin él.

Para realizar el muestreo de las señales se utilizó un sensor mioeléctrico MyoWare para obtener las señales EMG. Dicho sensor filtra, rectifica, amplifica la señal y la transforma a digital, lo que permite guardarla en una memoria microSD.

Las señales se extrajeron del músculo recto femoral, ya que sus principales funciones son extensión de la rodilla y flexión de la cadera.

Se utilizó el controlador Arduino, para convertir las señales de analógico a digital, ya que por medio del puerto USB permite enviar los valores de las señales a la computadora y utilizarlas para el análisis de información.

Se realizaron las pruebas de entrenamiento de la red neuronal en Python, se utilizaron las librerías Numpy, Matplotlib, Pandas y Sklearn.

### **1.7. LIMITACIONES**

Se tomaron las señales EMG con el método no invasivo o superficial, a pesar de que no es tan exacto como el invasivo. Porque la inserción de los electrodos de aguja es bastante dolorosa y además requiere la supervisión médica, la electromiografía invasiva se limita a usos clínicos y de carácter médico.

Solo se contó con dos sensores los cuales fueron colocados en cada una de las piernas de la persona. Porque solo se contó con presupuesto para dos sensores y con estos dos fue suficiente para detectar la intensidad de caminar.

Solo se realizaron 250 pruebas, porque realizar más requiere dispositivos de muestreo más exactos, se requieren más sensores y dispositivos de almacenamiento más grande, y estamos limitados a tal presupuesto.

Las pruebas se realizaron solamente una persona que tiene la discapacidad física de diplejía espástica. Porque es la única persona disponible para realizar las pruebas del muestreo de señales.

### **1.8. ORGANIZACIÓN DEL DOCUMENTO**

Este documento está organizado de la siguiente forma, en el Capítulo 2 se presentan los conceptos teóricos más relevantes que dan sustento al desarrollo de

la tesis. En el Capítulo 3 se describe la metodología desarrollada con la finalidad de adquirir y clasificar señales mioeléctricas extraídas del músculo recto femoral. En el Capítulo 4 se presentan los resultados obtenidos. Finalmente, el Capítulo 5 presenta las conclusiones que se obtuvieron con el desarrollo del proyecto.

# CAPÍTULO 2

## **MARCO TEÓRICO**

---

Uno de los factores más importantes en los controladores protésicos y ortopédicos es la capacidad de detectar la intención de la persona de realizar una determinada actividad, como estar de pie, caminar y sentarse. Para estas aplicaciones, la electromiografía (EMG) se ha utilizado ampliamente, los patrones de la señal (EMG) varían entre diferentes individuos [7].

El capítulo está estructurado de la siguiente manera, la Sección 2.1 muestra los conceptos básicos y la Sección 2.2 muestra algunos trabajos relacionados con el presente proyecto.

### **2.1. CONCEPTOS BÁSICOS**

En esta sección se presentan los conceptos teóricos de los elementos más relevantes para el desarrollo del presente documento de tesis.

#### **2.1.1 DISCAPACIDADES FÍSICAS**

La discapacidad física es una alteración del aparato motor causada por un funcionamiento deficiente del sistema nervioso central, del sistema muscular, del sistema óseo o de una interrelación de los tres sistemas que dificulta o imposibilita la movilidad funcional de una o diversas partes corporales [8].

#### **2.1.2 DIPLEJÍA ESPÁSTICA**

La diplejía espástica es un tipo de parálisis cerebral que afecta al control de los músculos y a la coordinación motora. Las personas sufren un aumento exagerado

del tono muscular, reflejos exagerados y rigidez (lo que se denomina espasticidad). Se dan sobre todo en la parte inferior del cuerpo (piernas), y afectan al movimiento, coordinación y equilibrio. Los síntomas y la gravedad de esta condición pueden variar mucho de una persona a otra [9].

### **2.1.3 MÚSCULOS ESQUELÉTICOS**

En anatomía humana, el sistema muscular es el conjunto de los más de 650 músculos del cuerpo, cuya función principal es generar movimiento, ya sea voluntario o involuntario, músculos esqueléticos y viscerales, respectivamente. El sistema muscular permite que el esqueleto se mueva, mantenga su estabilidad y la forma del cuerpo. En los vertebrados se controla a través del sistema nervioso, aunque algunos músculos (tales como el cardíaco) pueden funcionar en forma autónoma. Aproximadamente el 40% del cuerpo humano está formado por músculos. Los músculos esqueléticos permiten caminar, correr, saltar, facultan una multitud de actividades voluntarias. A excepción de los reflejos que son las repuestas involuntarias generadas como resultado de un estímulo. En cuanto a los músculos de funcionamiento involuntario, se puede especificar que se desempeñan de manera independiente a nuestra voluntad, pero son supervisados y controlados por el sistema nervioso [1].

### **2.1.4 MÚSCULO RECTO FEMORAL**

Su función principal es generar movimientos mediante su capacidad para contraerse y relajarse de forma coordinada [1]. Cada musculo tiene funciones específicas. En particular, las principales funciones del músculo recto femoral son la extensión de la rodilla y flexión de la cadera, el músculo aplica una fuerza en cada movimiento que implica el estiramiento de la rodilla (caminar, subir las escaleras, levantarse cuando está sentado). En la Figura 5 se muestra la superficie de los músculos donde se colocan los electrodos superficiales para tomar las señales mioeléctricas [10].



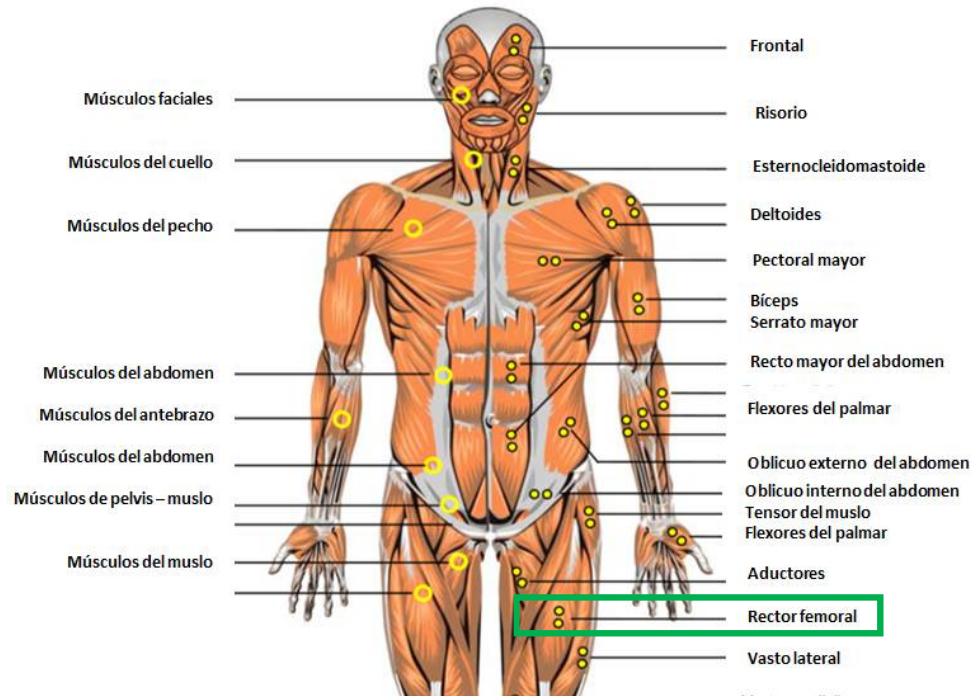


Figura 5 Posiciones anatómicas para colocar los electrodos superficiales [10].

### 2.1.5 APRENDIZAJE MÁQUINA

Aprendizaje máquina es la ciencia de programar computadoras para que puedan aprender de los datos para resolver un problema, en general, un problema de aprendizaje considera un conjunto de  $n$  muestras de datos y luego trata de predecir propiedades de datos desconocidos. Si cada muestra es más que un solo número y por ejemplo, una entrada multidimensional (también conocida como datos multivariados), se dice que tiene varios atributos o características [14].

Existen 3 enfoques de aprendizaje: Supervisado, no supervisado y semi-supervisado.

En el aprendizaje supervisado se cuenta con datos que aparte de contar con atributos, también incluyen la etiqueta o valor a predecir. Las tareas de predicción en el enfoque supervisado se dividen en clasificación y regresión [14]:

- Clasificación: las muestras pertenecen a dos o más clases de los datos ya etiquetados, el objetivo es predecir la clase de datos no etiquetados.
- Regresión: donde ciertas variables conocidas de los datos, y usando datos históricos, se puede hacer predicciones sobre lo desconocido.

El aprendizaje no supervisado es en el que los datos de entrenamiento consisten en un conjunto de vectores de entrada  $x$ , sin ninguna clasificación. El objetivo en el problema puede ser descubrir grupos de ejemplos similares dentro de los datos, donde se denomina agrupamiento.

En el aprendizaje semi-supervisado utiliza datos de entrenamiento etiquetados y no etiquetados, normalmente una pequeña cantidad de datos etiquetados junto a una gran cantidad de datos no etiquetados.

### **2.1.6 REDES NEURONALES ARTIFICIALES**

Las redes neuronales artificiales se basan en la analogía que existe en el comportamiento y función del cerebro humano, en particular del sistema nervioso, el cual está compuesto por redes de neuronas biológicas que poseen bajas capacidades de procesamiento. Sin embargo, toda su capacidad cognitiva se sustenta en la conectividad de éstas. Las redes neuronales artificiales están formadas por conjuntos de neuronas que se agrupan en capas, de forma que todas las neuronas de una misma capa comparten ciertas características. Que proporcionan uno de los mecanismos mediante los que se puede conseguir que una computadora aprenda [11].

Las redes neuronales artificiales son modelos matemáticos que intentan reproducir el comportamiento del cerebro humano. El principal objetivo de este modelo es la construcción de sistemas capaces de presentar un cierto comportamiento inteligente. Esto implica la capacidad de aprender a realizar una determinada tarea. La Red Neuronal Artificial se compone de los siguientes elementos.

- Las entradas  $x_{ji}$  que representan los datos que se van a analizar o son señales que provienen de otras neuronas ocultas.
- Los pesos  $w_{ji}$  son la intensidad de la sinapsis que conecta dos neuronas
- $f()$  es la función que establece el umbral que la neurona debe sobrepasar para activarse.

En la Figura 6a se representa el modelo de la neurona biológica y la Figura 6b el modelo matemático de la neurona artificial.




Figura 6 a) Modelo de la neurona biológica, b) modelo matemático de la neurona artificial [11]

Las señales de entrada a una neurona artificial  $x_{j1}, x_{j2}, \dots, x_{jn}$  son variables continuas en lugar de pulsos discretos, como se presentan en una neurona biológica. Cada señal de entrada es potencializada o atenuada por el peso sináptico o intensidad de conexión cuya función es analógica a la función de las sinapsis de la neurona biológica. Los pesos pueden ser positivos (excitatorios), o negativos (inhibitorios), el nodo sumatorio acumula las señales ponderadas y las pasa a la salida a través de una función umbral, también conocida como función de activación o transferencia [12].

### 2.1.7 REDES NEURONALES CLÁSICAS

Estas se suelen llamar redes neuronales o perceptrones multicapa, con estos términos se refieren a las redes neuronales clásicas que iniciaron en el área de la

inteligencia artificial. Los componentes de las redes neuronales se llaman neuronas artificiales, son unidades de cálculo computacional que tienen entradas multiplicadas por unos coeficientes o pesos, estableciendo mayor o menor importancia a unas entradas en comparación con las otras y emplean una función de activación para obtener una salida [13].

#### 2.1.7.1 LOS PESOS DE UNA NEURONA

Son coeficientes entrenables que permiten determinar en que medida es importante e influye cada variable de entrada en la salida, además de los pesos en las entradas se añade siempre otro peso que se llama sesgo (en inglés *bias*), el sesgo se utiliza para compensar desviaciones (en inglés *offsets*) producidos por los valores de entrada y sus escalas.

#### 2.1.7.2 LA FUNCIÓN DE ACTIVACIÓN

Las entradas se multiplican por los pesos de cada rama y se suman todos ellos junto con el bias, a esto se le aplica una función de activación, la función de activación es la encargada de mapear esta suma de entradas a la salida y es la clave de la no linealidad añadida a las redes neuronales.

#### 2.1.7.3 LA NEURONA

Las neuronas están dispuestas en redes de neuronas. Una fila de neuronas se llama una capa y una red puede tener múltiples capas. La arquitectura de las neuronas en la red se llama a menudo la topología de la red.

#### 2.1.7.4 CAPA DE ENTRADA

Esta capa es la que contiene las entradas del sistema, no es una capa que contenga neuronas o pesos. Son simplemente las entradas al sistema de redes neuronales.

### 2.1.7.5 CAPAS OCULTAS

Se llaman así, porque no se puede entrar a ellas directamente, sino que tiene que ser a través de la capa de entrada. Este tipo de capas puede contener miles de unidades de cálculo neuronal.

### 2.1.7.6 CAPA DE SALIDA

Es la encargada de expedir las salidas correspondientes a las entradas. Este tipo de capas son decisivas en el funcionamiento del sistema. La Figura 7 muestra una red neuronal con las entradas, capa de entrada, capa oculta y la capa de salida.




Figura 7 Arquitectura de una red neuronal clásica [12]

## 2.1.8 ELECTROMIOGRAFÍA

La EMG es el registro de los potenciales bioeléctricos asociados con la actividad de los músculos, además de la detección, análisis y uso de dicha señal eléctrica. La señal de la electromiografía es la representación de la corriente generada por el flujo iónico a través de la membrana de las fibras del músculo liso y estriado propagándose hasta los tejidos de la piel [15].

El potencial bioeléctrico de la señal de electromiografía varía dependiendo de las condiciones en que se encuentren las células excitables (células que se encuentran en tejidos nerviosos, musculares y glandulares), los dos posibles estados para una célula excitable son [16]:

- Estado de reposo: es el estado donde las células excitables mantienen un potencial alrededor de los  $-90\text{ mV}$ .
- Estado activo: en dicho estado las células excitables tienen un potencial eléctrico entre los  $-55$  y  $30\text{ mV}$ .

Adicionalmente, la frecuencia de la señal de electromiografía se encuentra en una banda de 0 a 500 Hz con energía dominante en 50 Hz y 150 Hz, sin embargo, en ciertos casos se pueden encontrar señales de EMG con frecuencias hasta de 2000 Hz [14].

Como la electromiografía tiene por objeto el estudio de la actividad muscular, no se puede pasar por alto la actividad de las unidades motoras (UM). En una contracción muscular voluntaria la fuerza es modulada por una serie de cambios en la frecuencia de la actividad de las UMs, es decir, que la frecuencia de disparo de los potenciales de las UMs depende de la fuerza aplicada y la velocidad de contracción muscular. Existen dos formas principales de registrar las señales electromiográficas, la electromiografía de superficie o no invasiva y la electromiografía invasiva [15].

### **2.1.9 ELECTROMIOGRAFÍA SUPERFICIAL**

La electromiografía de superficie (SEMG, por sus siglas en inglés: *Static and Dynamic Surface Electromyography*) es una técnica que se basa en el uso de los electrodos superficiales, estos electrodos son colocados directamente sobre la piel del músculo del cual se quiere obtener información. La SEMG tiene la peculiaridad de que los registros obtenidos mediante ella muestran actividad poblacional de las unidades motoras, esto es debido a que los electrodos, al estar en la superficie del músculo, no son capaces de captar la señal de una sola unidad motora, sino que, por el contrario, captan la información de varias UMs [17]. Es por esta razón que esta técnica no es muy utilizada para diagnósticos médicos muy precisos. Por otro lado, el uso de los electrodos superficiales es mucho más adecuado para el estudio del comportamiento promedio de la actividad eléctrica de un músculo o grupo de

músculos, lo cual es muy utilizado para detectar fatiga muscular y para monitoreo del rendimiento de deportistas, la SEMG es la técnica que se utiliza principalmente para el desarrollo de prótesis mioeléctricas, donde el uso de los electrodos de aguja no es muy cómodo para el paciente. La Figura 8 muestra electrodos superficiales de gel los más utilizados en las investigaciones de señales mioeléctricas y un ejemplo de cómo se colocan en los músculos.




Figura 8 Electrodo Superficiales [17]

Para electrodos de superficie, los electrodos pre-gelificados de plata/cloruro de plata son los electrodos más utilizados y recomendados para el uso general (SENIAM [18]). Además de un manejo fácil y rápido, los aspectos higiénicos no son un problema al usar este tipo de electrodo desechable. El diámetro del electrodo (área conductora) debe dimensionarse hasta 1 cm o más. Los electrodos desechables comerciales se fabrican como electrodos de gel húmedos o electrodos de gel adhesivo. Generalmente los electrodos de gel húmedos tienen mejor condición de la conducción que los electrodos adhesivos del gel. El último tiene la ventaja que pueden ser reposicionados en caso de errores [10], este es el tipo de electrodo que se utilizó para las pruebas realizadas.

### 2.1.10 ELECTRODOS

Los electrodos son los elementos de sensor en la cadena de medición, haciendo contacto con el cuerpo del sujeto para detectar cambios bioeléctricos, de esta manera actúan como una especie de transductor electroquímico para las reacciones que ocurren dentro del organismo vivo. Los electrodos hacen una transferencia iónica del tejido vivo del cuerpo hacia un dispositivo electrónico, el cual se encarga

de procesarla para posteriormente obtener información útil de la medición, entre las señales biológicas más estudiadas y registradas se encuentran las electrocardiográficas (ECG), electroencefalográficas (EEG) y electromiográficas (EMG), por citar algunas [19].

### 2.1.11 SENSORES MIOELÉCTRICOS

El Sensor Muscular MyoWare de la Figura 9 mide, filtra, rectifica y amplifica la actividad eléctrica de un músculo y produce una salida de señal analógica que puede ser fácilmente leída por un microcontrolador, habilitando interfaces de control muscular [20]. Este sensor de Advancer Technologies mide la actividad muscular a través del monitoreo de potencial eléctrico generado por las células musculares. A esto se le conoce como la electromiografía (EMG por sus siglas en inglés) [17]. El sensor amplifica y procesa la actividad eléctrica compleja de un músculo y la convierte en una señal analógica simple que puede ser fácilmente leída por cualquier microcontrolador con un convertidor analógico a digital (*analog to digital converter*, ADC por sus siglas en inglés), como un Arduino. A medida que el grupo muscular flexiona, aumenta el voltaje de salida del sensor. La relación exacta entre el voltaje de salida y la actividad muscular puede ser ajustada usando un potenciómetro de ganancia.




Figura 9 Sensor Muscular MyoWare [20]



## 2.1.12 SEÑALES ANALÓGICAS

Las señales analógicas, se producen por un fenómeno electromagnético y se representan por una función matemática continua donde varía el período y la amplitud en función del tiempo. Generalmente la intensidad, temperatura, presión, tensión, mecánica y potencia son portadoras de este tipo de señal. Las señales analógicas se pueden percibir en todos los lugares, por ejemplo, la naturaleza posee un conjunto de estas señales como la luz, la energía, el sonido, entre otros, estas señales varían constantemente [21].

Cuando los valores del voltaje o la tensión tienden a variar en forma de corriente alterna se produce una señal eléctrica analógica. En este caso se incrementa durante medio ciclo el valor de la señal con signo eléctrico positivo, y durante el siguiente medio ciclo, va disminuyendo con signo eléctrico negativo. Es desde este momento que se produce un trazado en forma de onda senoidal, ya que éste da a lugar a partir del cambio constante de polaridad de positivo a negativo. Las señales de cualquier comunicación electrónica o de cualquier ruido pueden presentar algunas complicaciones, por ejemplo, estas pueden ser modificadas a través del ruido de forma no deseada. Es por estas razones que se recomienda que la señal antes de ser procesada se acondicione, de este modo no generará estas modificaciones imprevistas. En la Figura 10 se puede observar la representación gráfica de las señales análogas.




Figura 10 Señales análogas [21]

### 2.1.13 SEÑALES DIGITALES

El término de señal hace referencia al cambio de corriente de electricidad que se emplea para la transmisión de un dato. Digital, por su parte, es un adjetivo que menciona lo vinculado a los dedos o a los números de un dígito. Las señales digitales son aquellas cuyos signos representan ciertos valores discretos que contienen información codificada. Los sistemas que emplean señales digitales suelen apelar a la lógica binaria, de dos estados, los cuales son reemplazados por unos y ceros, que indican el estado alto o bajo del nivel de tensión eléctrica [21].

Una señal digital pierde poca calidad y puede reconstruirse por medio de un proceso de regeneración. Estas señales, además, pueden procesarse de manera sencilla y son poco susceptibles al ruido ambiental. Mientras que las señales analógicas son continuas, las señales digitales tienen la capacidad de pasar de un valor a otro sin atravesar los valores intermedios, cada señal digital sólo puede tomar dos estados, representados por unos y ceros.

En cualquier sistema electrónico, como una computadora, la información es leída a través del código binario. Las señales digitales que maneja una computadora, por lo tanto, son unos y ceros que el sistema sabe cómo interpretar para responder a las órdenes del usuario. En la Figura 11 se observa una representación gráfica de las señales digitales.




Figura 11 Señales digitales [21]

## **2.2. TRABAJOS RELACIONADOS**

El movimiento humano es una compleja red de vías neuronales y activaciones musculares influidas por muchos factores. Además, los funcionamientos internos de estos sistemas diferencian entre la gente sana y los pacientes con discapacidad [23]. Existen varios trabajos relacionados con el uso de las señales mioeléctricas, por ejemplo, para dar terapias físicas en los brazos y en las piernas, las señales mioeléctricas son extraídas del antebrazo o del músculo de la pierna, dependiendo de la terapia, con estas señales se identifica la intensidad de movimiento y por medio de un mecanismo acoplado al cuerpo ayudan a realizar los movimientos programados para la terapia física que requiere. Sin embargo, dependiendo de la persona y de la discapacidad, se genera el modelo que permite realizar la terapia. A continuación, se muestran trabajos relacionados con el análisis de señales mioeléctricas.

### **2.2.1 IMPORTANCIA DE LA SELECCIÓN MUSCULAR PARA EL ANÁLISIS DE LA SEÑAL EMG DURANTE LA REHABILITACIÓN DEL MIEMBRO SUPERIOR DE LOS PACIENTES**

El método de selección muscular desarrollado en [23] muestra la importancia de elegir los músculos que contribuyen a un movimiento específico. En la investigación reportada se utiliza este método para evaluar la parálisis y el nivel de recuperación de los pacientes con discapacidad de movimiento, al comparar las sinergias del lado afectado y no afectado del cuerpo. El método propuesto permite la selección de los músculos que contribuyen altamente a los movimientos específicos según la distribución de la energía y de la frecuencia de las señales EMG. Las personas que participaban realizaron la terapia basada en un volante en la rehabilitación superior del miembro como se muestra en la Figura 12. Los resultados finales demuestran que, con la selección apropiada de los músculos, es posible calcular un índice de la semejanza entre los brazos derechos e izquierdos (durante el movimiento simétrico) asociados al nivel de parálisis y a la recuperación potencial de un tema dado.

Las sinergias musculares se calculan a partir de un grupo de músculos que contribuyen a un movimiento específico, uno de los enfoques importantes introducidos en este trabajo es el desarrollo de un método para seleccionar cuáles son los músculos importantes que contribuyen al movimiento simétrico para un tema específico y una estrategia de rehabilitación. Este método tiene en cuenta el nivel de activación de cada músculo y también su sincronización con la frecuencia del momento realizado.

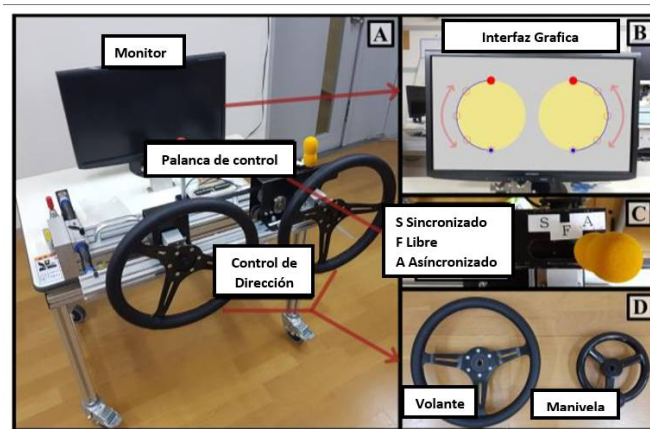


Figura 12 Sistema de tareas [23]

Tabla 1 Músculos ordenados por su contribución al movimiento evaluado [23]

Personas Sanas		Pacientes	
Músculo	Apariencia Muscular	Músculo	Apariencia Muscular
<b>Deltoides anterior</b>	<b>100%</b>	<b>Deltoides anterior</b>	<b>100%</b>
<b>Bíceps</b>	<b>90%</b>	<b>Pectoral mayor</b>	<b>100%</b>
<b>Pectoral mayor</b>	<b>80%</b>	<b>Bíceps</b>	<b>100%</b>
<b>Infraespinoso</b>	<b>70%</b>	<b>Braquioradial</b>	<b>90%</b>
<b>Erector de la columna</b>	<b>60%</b>	<b>Pronador redondo</b>	<b>75%</b>
<b>Pronador redondo</b>	<b>60%</b>	<b>Infraespinoso</b>	<b>15%</b>
<b>Braquioradial</b>	<b>35%</b>	<b>Erector de la columna</b>	<b>15%</b>
<b>Tríceps</b>	<b>0%</b>	<b>Tríceps</b>	<b>5%</b>
<b>Deltoides posterior</b>	<b>0%</b>	<b>Deltoides posterior</b>	<b>0%</b>

La Tabla 1 muestra los resultados obtenidos después de aplicar el proceso de selección muscular a todos los sujetos y dividirlos entre voluntarios sanos y pacientes. Los músculos se encuentran ordenados por su contribución al movimiento evaluado. La apariencia muscular muestra el porcentaje de veces que cada músculo fue seleccionado entre los cinco más relevantes dentro del grupo de voluntarios, 100% significa que fue en los primeros cinco de cada paciente analizado y 0% implica que no estaba entre los cinco primeros para ningún tema.

### **2.2.2 INTERFAZ DE BIOSEÑAL PARA ROBOT DE REHABILITACIÓN DE RODILLA QUE UTILIZA SEÑALES EMG DE LOS MÚSCULOS DEL MUSLO**

En la investigación descrita aquí se desarrolló un robot de rehabilitación de rodillas cuando el paciente se encuentra sentado [24] (Figura 13), el objetivo es trabajar con señales bioeléctricas de los músculos de los pacientes. Este tipo de robot es capaz de realizar todos los ejercicios activos y pasivos para mejorar la funcionalidad de los músculos de rodilla y muslo lesionados. La intención de los pacientes / operadores de mover la rodilla se detecta mediante actividades eléctricas de los músculos de la rodilla (EMG) registradas por encima de un músculo observado. Se aplica un soporte proporcional a la rodilla del paciente mediante el brazo del robot. Con el fin de estimar el torque generado en la articulación de la rodilla, se ha utilizado el modelo biomecánico simple de la articulación de la rodilla. Algunos parámetros de este modelo representan propiedades biomecánicas individuales del cuerpo humano que difieren de un paciente a otro. Por lo tanto, se ha realizado un programa de calibración para determinar estos parámetros individualmente. Para estimar el torque real producido en la articulación de rodilla, se insertan parámetros calibrados en el modelo biomecánico. Un refuerzo ortopédico está diseñado para medir las fuerzas de rodilla tanto en flexión como en extensión, este proceso es conocido como proceso de calibración. Los experimentos con un sujeto saludable han

indicado que la interfaz es capaz de estimar el torque real de la rodilla y también es capaz de soportar la rodilla del paciente durante el movimiento al proporcionar parte del torque pronosticado.

La rehabilitación ayudaría a los pacientes a compensar parte de sus déficits que no tienen tratamiento médico. El objetivo principal de la rehabilitación es aumentar la flexibilidad, la fuerza y la agilidad de las extremidades objetivo tanto como sea posible para que estén cerca de su estado natural.




Figura 13 Robot de rehabilitación de rodilla [24]

### **2.2.3 SISTEMA DE REDES NEURONALES PARA LA IDENTIFICACIÓN EN TIEMPO REAL DE LAS SEÑALES EMG**

En [25] se desarrolla una Red Neuronal Artificial (ANN) para la identificación en tiempo real de los patrones de señales de electromiografía (EMG). Se aplica como un dispositivo de interfaz entre el usuario y una prótesis robótica para la extremidad superior. Comienza con la caracterización de la extracción de la señal EMG, ubicación de los sensores, muestreo y definición de patrones, luego se definen la arquitectura y características de la ANN, la ANN se implementa en un sistema integrado, y realiza la validación cruzada y la validación en tiempo real del sistema propuesto, mediante matriz de confusión. La ANN incorporada implementada es del

tipo de perceptrón multicapa, arquitectura Feedforward, función de transferencia de tipo sigmoïdal, función de error cuadrático medio MSE y algoritmo Backpropagation. La exactitud promedio de la ANN es superior al 97.7%, confirmando la confiabilidad de usar este tipo de sistemas como dispositivos de interfaz entre un usuario y una prótesis robótica.

En este trabajo se realizó el diseño e implementación de un sistema embebido de reconocimiento de patrones de señal EMG en tiempo real, con el fin de optimizar en funcionamiento, desempeño y tamaño el sistema inteligente. En la Figura 14 se muestra la arquitectura software del sistema de reconocimiento de patrones basado en RNA. Consta de dos fases: fase de aprendizaje y la fase de identificación de patrones.

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. El esquema de aprendizaje de la presente RNA es un aprendizaje supervisado, ya que existe y se conoce un resultado deseado para cada entrada. Los algoritmos de aprendizaje se encargan de reducir el error de las salidas.

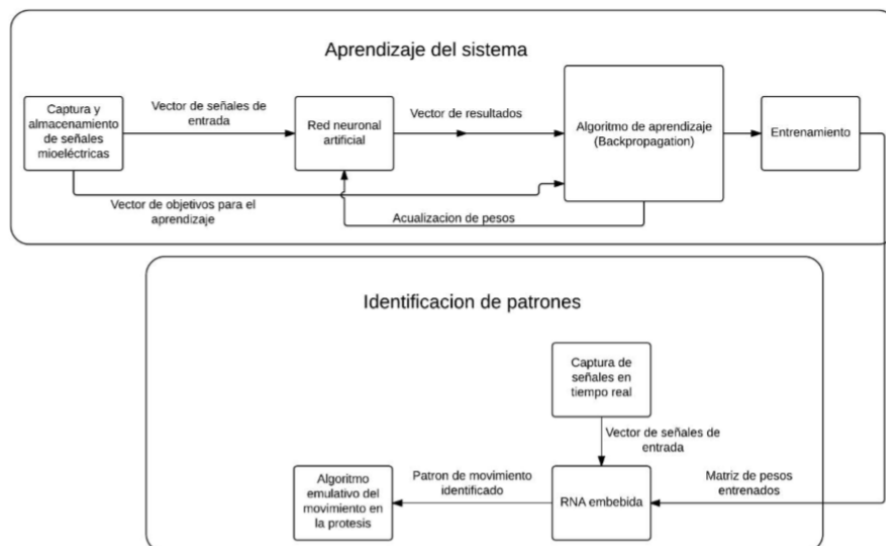


Figura 14 Arquitectura software del sistema de reconocimiento de patrones [25]

## 2.2.4 CLASIFICACIÓN DE EMG A TRAVÉS DE ÍNDICES LINEALES Y NO LINEALES POR MEDIO DE REDES NEURONALES ARTIFICIALES

En este trabajo [26] se extrajeron índices lineales y no lineales de la señal de electromiografía (EMG), el Valor Cuadrático Medio (RMS), el Valor Medio Absoluto (MAV), la Integral, la Integral Cuadrada Simple (SSI) y la Entropía Aproximada (ApEn). La señal de EMG fue adquirida del músculo flexor radial del carpo y del músculo extensor de los dedos durante tres maniobras de flexión y extensión de la muñeca, considerando la máxima contracción voluntaria (MVC), el 50% de la MVC, y movimientos pasivos. Con los índices extraídos se diseñaron dos redes neuronales artificiales para clasificar flexión-extensión y flexión-extensión-relajación. Los resultados de desempeño de clasificación de las dos redes mostraron porcentajes de eficiencia de 91.4% y 94.7%, para la flexión – extensión y flexión – extensión – relajación, las redes neuronales tuvieron un buen desempeño con los índices lineales y no lineales extraídos de la señal de EMG.

La adquisición de la señal de EMG se realizó con el sistema Biopac MP36 R a una frecuencia de muestreo de 1 kHz con un arreglo de electrodos bipolar como se muestra en la Figura 15.




Figura 15 Colocación bipolar de electrodos (a) del músculo flexor y (b) del músculo extensor [26]

El protocolo de adquisición de los datos consistió en la realización de tres maniobras. Durante la primera maniobra se instruyó a los sujetos para realizar contracciones máximas voluntarias (MVC), en la segunda maniobra se realizaron contracciones con una amplitud aproximada al 50% de la MVC de cada sujeto, y finalmente en la tercera maniobra se realizaron movimientos simples (pasivos) de



flexión y extensión, es decir, sin realizar fuerza activa. En las tres maniobras se realizaron 3 flexiones de muñeca y posteriormente 3 extensiones de muñeca.

Se implementaron dos RNA: la primera red (R1) considerando la clasificación entre flexión y extensión, la segunda red (R2) considerando 3 clases: flexión, extensión y relajación. Ambas redes fueron entrenadas con las maniobras previamente descritas. La arquitectura seleccionada fue de 20 neuronas en la capa de entrada, 10 neuronas en la capa oculta y en la capa de salida 2 y 3 neuronas para R1 y R2, respectivamente, utilizando una función de transferencia tangencial sigmoidea. El entrenamiento de la RNA fue de tipo supervisado.

Los resultados en la etapa de pruebas, R1 obtuvo una tasa de error de 8.6%, lo que significa que clasificó correctamente más del 91.4% de las ventanas temporales. R2 una tasa de error de 5.3%, clasificó correctamente más del 94.7%. Estos resultados muestran un buen desempeño por parte de las dos redes neuronales. Estos valores muestran que las redes tuvieron un entrenamiento apropiado y además que son capaces de realizar clasificaciones adecuadas.

### **2.2.5 RECONOCIMIENTO DE PATRONES DE LAS SEÑALES EMG POR REDES NEURONALES**

Este trabajo [27] trata de reconocer las señales de EMG mediante el uso de redes neuronales para clasificar los movimientos de la muñeca y con estos poder controlar movimiento de un brazo robótico. Los electrodos se colocan en las muñecas y luego se mide la EMG. Estas señales de EMG se clasifican en siete categorías, como neutral, arriba y abajo, derecha e izquierda, muñeca hacia adentro, muñeca hacia afuera mediante el uso de una red neuronal. La red neuronal aprende los espectros de FFT (Fast Fourier Transform) para clasificarlos. Se realizó el análisis de componentes principales utilizando el análisis simple de componentes principales antes de realizar experimentos de reconocimiento. El enfoque es efectivo para

clasificar las señales de EMG mediante simulaciones por computadora. Analizaron los valores de EMG desde la muñeca y realizaron experimentos utilizando la Transformada de Fourier (FFT) y una red neuronal.

Utilizan los métodos de aprendizaje: *Back-Propagation* (BP) y *forgetting Back-Propagation* (BPWF). Los porcentajes de acierto que se obtuvieron en este trabajo fueron los siguientes:

En la red *Back-Propagation* (BP), mover la muñeca hacía arriba da 65% de acierto, doblar a la derecha 70% de acierto, mover a la izquierda 81.67% de acierto, hacía abajo 86.67% de acierto, neutral 51.67% de acierto, ya que no realiza ninguna fuerza, giro hacia adentro 75% de acierto y giro hacía fuera 71.67% de acierto.

En la red *forgetting Back-Propagation* (BPWF), mover la muñeca hacía arriba da 70% de acierto, doblar a la derecha 67.33% de acierto, mover a la izquierda 76.33 de acierto, hacía abajo 87.67% de acierto, neutral 51.67% de acierto, ya que no realiza ninguna fuerza, giro hacia adentro 74% de acierto y giro hacía fuera 70.76% de acierto.

La red *Back-Propagation* (BP) tiene un mayor porcentaje de aciertos 71.67%, en comparación con la red *forgetting Back-Propagation* (BPWF) que se obtuvo el 70.76%.

### **2.2.6 DETECCIÓN DE LA INTENCIÓN DE MOVIMIENTO A PARTIR DE SEÑALES ELECTROMIOGRÁFICAS UTILIZANDO REDES NEURONALES**

En este artículo [28] tratan de determinar la intención de movimiento de la pierna de una persona amputada de una pierna, basándose en patrones generados de señales EMG. Se utilizó una red neuronal con una capa oculta y un autómata de estados para clasificar los patrones, fue posible clasificar tanto movimientos

estacionarios (estados que pueden permanecer constantes por un tiempo indefinido), como transitorios (estados que generalmente duran poco tiempo y es una transición entre dos movimientos continuos diferentes). Para las pruebas utilizaron siete tipos de señales distintas correspondientes a diferentes movimientos, y un vector de 8 características, obtuvieron resultados favorables para los movimientos estacionarios y medianamente favorables para los estados transitorios.

Se basan en un procedimiento para obtener las señales electromiográficas del cuerpo, realizan un tratamiento adecuado a través de filtros digitales, dividen la señal en secciones llamadas ventanas, extraen características de dichas ventanas (división de una señal en periodos iguales de tiempo) y con base a ellas determinan la intención de movimiento con la ayuda de una red neuronal artificial y un autómata de estados.

Utilizando un vector de características de cada ventana, este vector es la entrada de una red neuronal. Para crear el vector de características se obtuvo un conjunto de 8 parámetros los cuales describen la señal EMG. Estas características son, el valor medio absoluto, la varianza, la raíz media del cuadrado, los cruces por cero, la pendiente, la longitud de forma de onda, la desviación estándar ya la sumatoria de voltajes en una ventana.

La forma en la que se realizó la clasificación de las señales EMG, provenientes del músculo, fue a través del uso de una red neuronal. La red consta de 8 entradas, 5 neuronas en la capa oculta y 3 salidas, como se muestra en la Figura 16. Las 8 entradas corresponden a cada una de las características, contenidas en el vector de características, y las salidas corresponden a 3 movimientos principales los cuales son: parado, sentado y marcha.




Figura 16 Esquema de red neuronal aplicada al sistema [28]

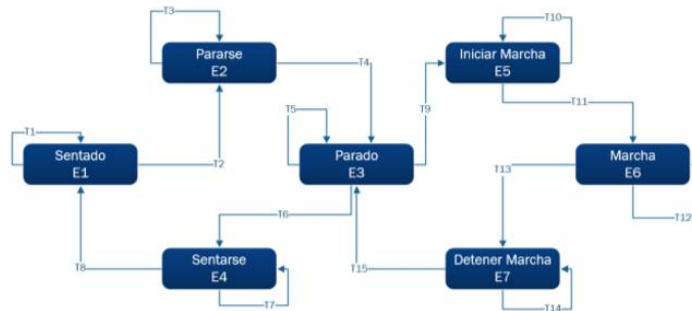


Figura 17 Diagrama del autómata de estados [25]

En la Figura 17 se muestra el diagrama del autómata de estados, los cuales representan todos los posibles movimientos de una pierna; sin embargo, dentro de estos estados existen dos tipos de movimientos estacionarios (Estados que pueden durar indefinidamente) y estados transitorios (estados que por lo general duran un leve periodo de tiempo). En la Tabla 2 se muestra la clasificación de los estados por su tipo.

Tabla 2 Clasificación de estados estacionarios y transitorios [28]

<b>Estados Estacionarios</b>	<b>Estados Transitorios</b>
Sentado	Pararse
Parado	Sentarse
Marcha	Iniciar Marcha
	Detener Marcha

Los resultados que obtuvieron se engloban en la respuesta proporcionada por la red neuronal, el autómata desarrollado y la probabilidad, en conjunto, estos tres aspectos clasifican la señal EMG de acuerdo con la intención de movimiento de una

persona como se muestra en la Tabla 3 estados estacionarios y en la Tabla 4 estados transitorios.

Tabla 3 Resultados obtenidos en las diferentes pruebas con datos de entrenamiento y datos desconocidos [28]

	<b>Sentado</b>	<b>Parado</b>	<b>Marcha</b>
Datos de entrenamiento	93.86% de éxito clasificación final 96.93% de éxito en la red neuronal	93.86% de éxito clasificación final 94.47% de éxito en la red neuronal	94.97% de éxito clasificación final 100% de éxito en la red neuronal
Datos desconocidos	93.38% de éxito en clasificación final 80.98% de éxito en clasificación en la red neuronal	90.13% de éxito en clasificación final 88.34% de éxito en clasificación en la red neuronal	91.85% de éxito en clasificación final 83.12% de éxito en clasificación en la red neuronal

Tabla 4 Resultados obtenidos en las diferentes pruebas con datos de entrenamiento y datos desconocidos [28]

	<b>Pararse</b>	<b>Sentarse</b>	<b>Iniciar Marcha</b>	<b>Terminar Marcha</b>
Datos de entrenamiento	66% de acierto en clasificación final	50% de acierto en clasificación final	83.3% de acierto en clasificación final	83.3% de acierto en clasificación final
Datos desconocidos	50% de acierto en clasificación final	40% de acierto en clasificación final	66.6% de acierto en clasificación final	66.6% de acierto en clasificación final

### **2.2.7 ADQUISICIÓN Y PROCESAMIENTO DE SEÑALES EMG PARA CONTROLAR MOVIMIENTO DE UN BRAZO HIDRÁULICO**

En este artículo [29] se presentó el diseño e implementación de un sistema electrónico para el registro de las señales electromiográficas de la extremidad superior del sujeto (humano). Se realiza una etapa de pre-procesamiento y procesamiento de las señales registradas, las técnicas utilizadas son: análisis wavelet (AW), análisis de componentes principales (ACP), transformada de Fourier (TF), transformada del coseno discreta (DCT), máquinas de soporte vectorial (SVM) y redes neuronales artificiales (RNA), estas técnicas las utilizaron para eliminar información poco relevante, reconocer zonas de interés, extraer patrones en cada grupo de señales y clasificar una nueva señal que controle en forma precisa el movimiento que quiere ejecutar el sujeto con el brazo Hidráulico.

El circuito implementado para la adquisición y el acondicionamiento de la señal EMG, constó de las etapas de: preamplificación, filtrado, amplificación, rectificación de onda completa y comunicación USB. Se realizó un sistema de adquisición de dos canales, uno conectado al antebrazo y otro al brazo, utilizaron 4 movimientos para controlar el sistema hidráulico, los movimientos utilizados fueron: mano, bíceps, hombro y quieto. La clasificación de las señales EMG de la extremidad superior se realizó mediante la implementación de dos redes neuronales probabilísticas (PNN) una para cada canal de adquisición, en el proceso de clasificación no se realizó ningún ajuste de pesos y sólo los patrones de salida son determinados mediante la comparación. Esta etapa de entrenamiento para la clasificación se lleva de manera satisfactoria, en este caso para las dos redes neuronales probabilísticas se usó una matriz de entrenamiento [9x20] para cada canal de adquisición, que consta de tres señales EMG de la extremidad superior de cada una teniendo como resultado de 9 a 20.

Los resultados de la extracción de características de las señales EMG de la extremidad superior que se realizaron utilizando, transformada de Fourier (TF),

discreta del coseno (DC), transformada de wavelet (TW) y análisis de energía (E), la técnica más eficiente para extraer patrones es la energía de la señal, de acuerdo con la tabla de resultados que se muestra en la Tabla 5.

Tabla 5 Clasificación correcta para las diferentes técnicas de extracción de patrones [29]

TÉCNICA	% DE CLASIFICACIÓN
DC	21.22
TF	23.33
WAVELET	25.66
ENERGÍA	93.12

### **2.2.8 UN ENFOQUE DE APRENDIZAJE PROFUNDO PARA LA CLASIFICACIÓN BASADA EN EMG DE FASES DE LA MARCHA DURANTE LA MARCHA A NIVEL DEL SUELO**

Proponen un enfoque de aprendizaje profundo (deep learning) para la clasificación basada en electromiografía de superficie (EMGs) [30], en condiciones de caminata natural (similares a las caminatas diarias), superando las limitaciones de un entorno controlado, como caminar en la caminadora. Con este objetivo, obtuvieron señales EMGs de ocho músculos de las extremidades inferiores en aproximadamente 10.000 pasos de 23 adultos sanos durante el recorrido a nivel del suelo, siguiendo un camino en forma de ocho, incluida la desaceleración natural, la inversión, la curva y la aceleración. Mediante una evaluación exhaustiva, mostraron que el uso de un perceptrón multicapa para aprender características ocultas proporciona actuaciones de vanguardia al tiempo que evita la ingeniería de características. Los resultados, mostraron una exactitud de clasificación promedio de 94.9 para los sujetos aprendidos y 93.4 para los no aprendidos.

El objetivo de esta investigación fue proponer un enfoque basado en la red neuronal artificial (ANN) para clasificar los eventos de la marcha (postura correcta y fases de balanceo) y predecir la señal de contacto con el piso del pie a partir de señales EMGs, en condiciones similares a las de todos los días para caminar.

Se realizó una normalización mínima-máxima de cada señal muscular mapeando así los valores en el intervalo [0-1]. Para entrenar al clasificador, se dividió las señales en 20 ventanas de muestras EMGVector. Cada EMGvector estaba compuesto de 20 secuencias de ocho elementos. Cada elemento representa los valores de la señal EMG de los ocho músculos en esa única muestra de tiempo como se muestra en la Figura 18.




Figura 18 Estructura de los vectores entrada a las redes neuronales artificiales [30]

## 2.2.9 TABLA COMPARATIVA DE TRABAJOS RELACIONADOS

En la Tabla 6 se muestra un cuadro comparativo de los trabajos de investigación, comparando de que músculos se extrajeron las señales EMG, la cantidad de sensores que utilizaron, el modelo de red neuronal que utilizaron y el objetivo de la investigación.



Tabla 6 Estado del arte

No	Investigación	Parte del Cuerpo	Señales EMG	Redes Neuronales	Objetivo
1	Importancia de la selección muscular para el análisis de la señal EMG durante la rehabilitación del miembro superior de los pacientes	Brazo	18 sensores		Terapia de rehabilitación
2	Interfaz de bioseñal para robot de rehabilitación de rodilla que utiliza señales EMG de los músculos del muslo	Rodilla	6 sensores		Terapia de rehabilitación
3	Sistema de redes neuronales para la identificación en tiempo real de las señales EMG	Brazo	1 sensor	27 entradas 3 capas Ocultas de 27 neuronas cada una 4 neuronas de salida	4 movimientos de la mano
4	Clasificación de EMG a través de índices lineales y no lineales por medio de redes neuronales artificiales	Ante Brazo	1 sensor	20 entradas 1 capa oculta de 10 neuronas 3 neuronas de salida	3 movimientos de la mano
5	Reconocimiento de patrones de las señales EMG por redes neuronales	Ante Brazo	4 sensores	516 Entradas 1 capa oculta con 20 neuronas 7 neuronas de salida	7 movimientos de la mano
6	Detección de la intención de movimiento a partir de señales electromiográficas utilizando redes neuronales	Pierna	1 sensor	8 entradas 1 capa oculta con 5 neuronas 3 neuronas de salida	3 movimientos: parado, sentado, acostado NO DISCAPACITADOS Para amputados El porcentaje de acierto más alto fue de 83.3%
7	Adquisición y procesamiento de señales EMG para controlar movimiento de un brazo hidráulico	Brazo	2 sensores	9 entradas 1 capa oculta con 20 neuronas 4 neuronas de salida	4 movimientos de control brazo hidráulico
8	Un Enfoque de aprendizaje profundo para la clasificación basada en EMG de fases de la marcha durante la marcha a nivel del suelo	Piernas	8 sensores	160 entradas 4 capas ocultas, de 1024, 512, 256, 128 neuronas cada una Salida binaria 0 o 1	Predecir la señal de contacto pie-piso a partir de las señales EMG, para la clasificación de las fases de la marcha NO DISCAPACITADOS

En base a los trabajos de investigación analizados se tomó la decisión de utilizar sensores para obtener las señales EMG del músculo recto femoral y utilizar una red neuronal para clasificar e identificar la intención de caminar de una persona con discapacidad. El objetivo de los trabajos de investigación que se mencionan en la tabla son terapias de rehabilitación, control de brazos robóticos y el de este proyecto es identificar la intención de caminar. La aplicación de estos trabajos de investigación es para personas amputadas y que no tienen parálisis cerebral, el trabajo de investigación que estamos presentando es para una persona con parálisis cerebral y con diplejía espástica.

# CAPÍTULO 3

## **METODOLOGÍA PARA LA ADQUISIÓN Y CLASIFICACIÓN DE SEÑALES MIOELECTRICAS**

---

La señal mioeléctrica (EMG) es una medida de la actividad eléctrica de los músculos y generalmente se representa como una función del tiempo, definida en términos de amplitud, frecuencia y fase [19]. Esta señal puede emplearse en diversas aplicaciones, incluidos los diagnósticos de enfermedades neuromusculares, el control de dispositivos de asistencia como dispositivos protésicos / ortopédicos, el control de máquinas, robots, computadoras, etc. Por tanto, el estudio de dichas señales puede contribuir a aumentar la calidad de vida de las personas discapacitadas o de edad avanzada. El propósito de este trabajo es realizar una metodología de adquisición y clasificación de señales mioeléctricas para la detección de la intención de caminar de una persona con diplegia espástica usando una red neuronal artificial (ANN). En este proyecto se utilizó un modelo de red neuronal de aprendizaje supervisado para la clasificación de las señales EMG.

El capítulo está estructurado de la siguiente forma: la Sección 3.1 presenta los pasos de la metodología. En la sección 3.2 se describe el dispositivo electrónico usado para la adquisición de señales EMG. La sección 3.3 muestra el músculo donde se colocan los sensores para tomar las señales. La Sección 3.4 describe la extracción de señales EMG y la conversión analógica a digital por medio de la tarjeta Arduino. La sección 3.5 describe el proceso de muestreo y clasificación de señales que son utilizadas para identificar la intención de caminar. El análisis de las señales EMG se muestra en la sección 3.6. La sección 3.7 muestra una breve descripción del estudio de la biomecánica de la marcha. En la sección 3.8 se explica el modelo de la red neuronal utilizada para identificar la intención de caminar.

### 3.1. METODOLOGÍA GENERAL

En la Figura 19 se muestra un diagrama de la metodología propuesta. Durante la primera fase a) se determinó qué sensor utilizar para extraer las señales EMG. En la segunda fase b) se identificó el músculo sobre el cual se deberían extraer las señales. En la fase c) utilizando una tarjeta Arduino, se tomaron las señales EMG. En la fase d) se almacenan las señales EMG en una MicroSD. En la fase e) se realiza el análisis de las señales que se almacenan en la MicroSD. En la fase f) se determinó el tiempo que tarda en dar un paso. En la fase g) se realizaron pruebas con un modelo de una red neuronal de aprendizaje supervisado para identificar la intensidad de caminar. Las secciones 3.2 a la 3.8 brindan una explicación más detallada de cada una de las fases.

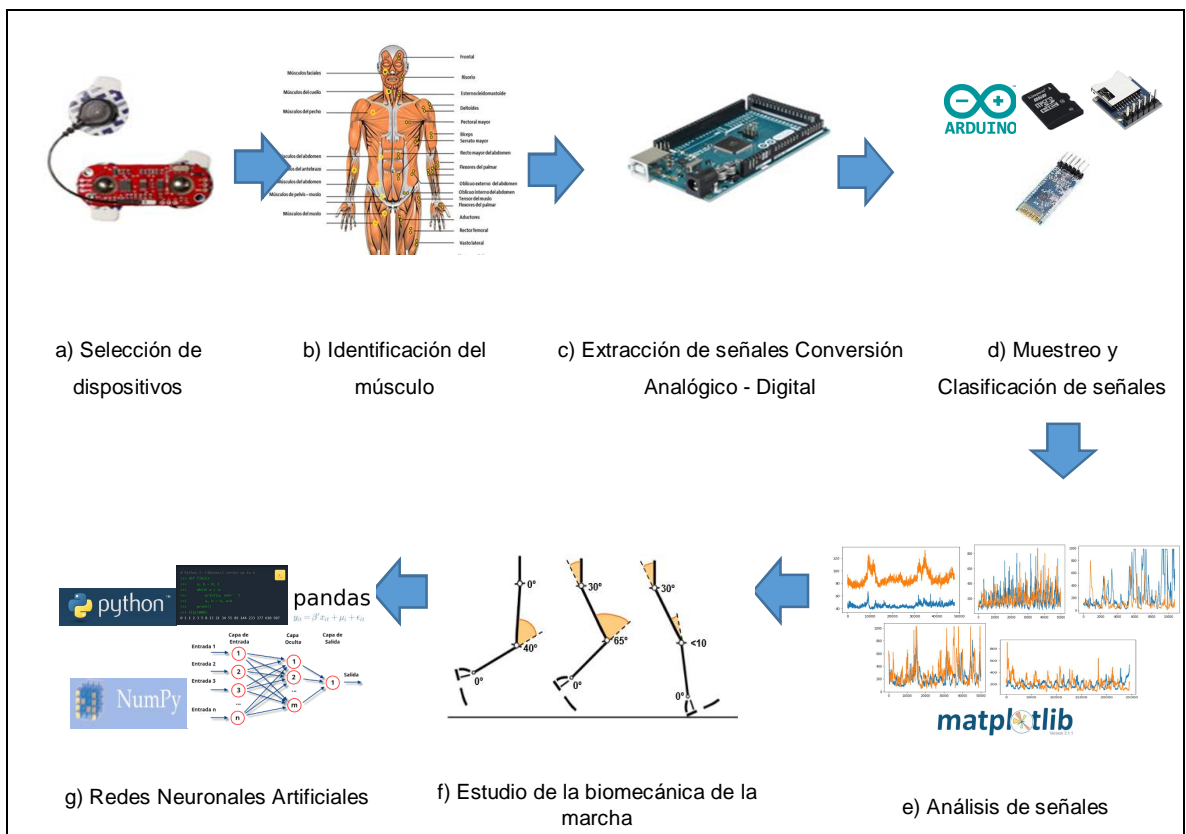


Figura 19 Arquitectura general del proyecto

### 3.2. SELECCIÓN DE DISPOSITIVOS PARA EXTRACCIÓN DE SEÑALES

La señal mioeléctrica ha demostrado su importancia y superioridad en el control de prótesis robóticas artificiales en las últimas décadas, lo que hace posible que los discapacitados físicos puedan usar su propia intención para realizar actividades diarias como caminar, agarrar, levantar objetos, etc. [31]. La señal mioeléctrica se puede extraer colocando electrodos en la piel por encima del músculo que se analiza, lo que se denomina señal de electromiografía superficial.

En este proyecto se utilizan electrodos superficiales y el sensor MyoWare que se muestra en la Figura 20, por su fácil adquisición, instalación rápida, fácil y segura, y la capacidad de procesamiento de señales mioeléctricas.




Figura 20 Sensor Muscular MyoWare

Las características del sensor mioeléctrico MyoWare son las siguientes:

- Dimensiones: 53 mm x 20 mm excluyendo el cable del electrodo que mide 76 mm.
- Voltaje de operación 2.9 V a 5.7 V.
- Voltaje análogo de salida desde 0V a +Vs (suministro de voltaje).
- Ganancia ajustable.
- Salidas EMG procesadas y sin procesar.
- Conectores de los electrodos en la placa.
- LEDs indicadores: uno encendido y otro que brilla cuando el músculo se flexiona.
- Interruptor de encendido.

- Protección de polaridad inversa.
- Dos agujeros de montaje (para tornillo M3).

Las especificaciones eléctricas del sensor mioeléctrico MyoWare se pueden observar en la Tabla 7.

Tabla 7 Especificaciones eléctricas del sensor mioeléctrico MyoWare

Parámetro	Mín	Recomendado	Máx
Tensión de alimentación	+2.9 V	+3.3 V o +5 V	+5.7 V
Ganancia ajustable de potenciómetro	0.01 $\Omega$	50 k $\Omega$	100 k $\Omega$
Voltaje de señal de salida			
EMG procesada	0V	-	+Vs
EMG sin procesar (Centrada alrededor de +Vs/2)	0V	-	+Vs
Impedancia de entrada	-	110 G $\Omega$	-
Corriente de suministro	-	9 mA	14 mA
Radio de módulo común de rechazo	-	110	-

Para unirse a la piel, el sensor requiere tres Electrodo ECG que se acoplan a los conectores de estilo broche de presión del sensor, lo cual hace que sea fácil conectar y desconectar los electrodos. Dos conectores están ubicados directamente en la tarjeta (PCB *Printed circuit boards*) y el tercero está ubicado en el extremo del cable de electrodo.

### 3.3. IDENTIFICACIÓN DEL MÚSCULO

Los músculos son tejidos blandos que permiten el movimiento de los huesos y de las articulaciones. De varias formas y tamaños, los músculos representan casi la mitad del peso del cuerpo humano [1]. Cualquier tipo de músculo se compone de fibras musculares, tejido conjuntivo nervioso y vasos sanguíneos. El músculo se puede considerar como un órgano en sí mismo, o bien como tejido que forma parte de otro órgano.

El objetivo del proyecto es de adquisición y clasificación de señales mioeléctricas para la detección de la intención de caminar de una persona con diplegia espástica, por tanto, se buscó información del funcionamiento de los músculos de las piernas,

encontrando que cada músculo tiene funciones específicas. En particular, las principales funciones del músculo recto femoral son la extensión de la rodilla y flexión de la cadera, el músculo aplica una fuerza en cada movimiento que implica el estiramiento de la rodilla (caminar, subir las escaleras, levantarse cuando está sentado).

Dentro de las recomendaciones para la correcta adquisición de señales EMG se encuentran:

- Preparación de zona de detección, la zona sobre la cual serán colocados los sensores mioeléctricos debe ser limpiada adecuadamente, ya que las mediciones son afectadas si la zona no está lo suficientemente limpia.
- Posicionamiento de los electrodos: con base en la normatividad de SENIAM [18], la posición longitudinal es la forma más práctica de trabajar, los electrodos de captación se colocan a unos 20 mm de distancia entre centros y el electrodo de referencia se ubica en cualquier parte del músculo.
- Alimentación del circuito para obtener las señales: la alimentación del circuito debe ser independiente para evitar señales de ruidos.

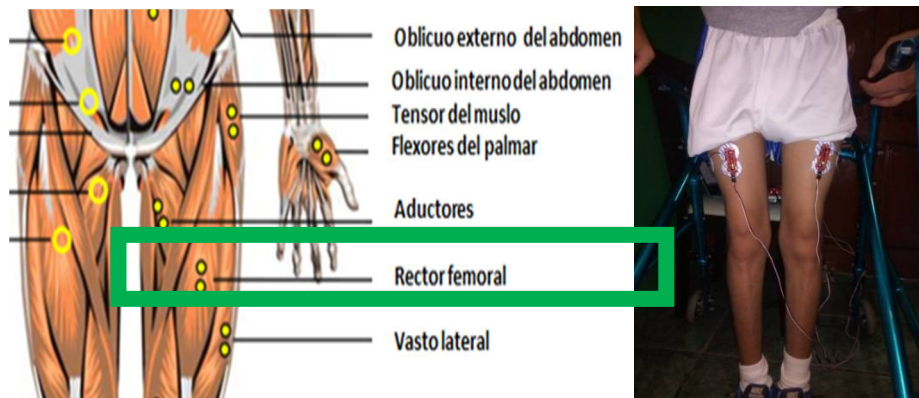


Figura 21 Ubicación y conexión de los sensores

En la Figura 21 se muestra la ubicación y conexión de los sensores para obtener las señales mioeléctricas del músculo recto femoral de las piernas. El lado izquierdo

de la Figura 21, muestra el lugar donde se ubica el músculo recto femoral y en el lado derecho, muestra la conexión de los sensores MyoWare para obtener las señales mioeléctricas.

### 3.4. EXTRACCIÓN DE SEÑALES CONVERSIÓN ANALÓGICO DIGITAL

La tarjeta Arduino es una plataforma de prototipos electrónica de código abierto (open - source) basada en hardware y software flexibles y fáciles de usar [22]. Los proyectos donde se utiliza una tarjeta de Arduino pueden ser autónomos o se pueden comunicar con software en ejecución en una computadora, dado que la tarjeta tiene puertos de comunicación de entrada y salida.

En este proyecto se utiliza un Arduino nano (Figura 22), basado en el microcontrolador ATmega328. La tarjeta tiene una entrada mini-usb a través de la cual se sube el código fuente para la ejecución de los comandos, 14 puertos digitales de entrada/salida, 8 puertos análogos, una memoria de 16 KB, 1 KB de SRAM y 512 bytes de EPROM.



Figura 22 Arduino Nano [22]

El sensor MyoWare de la pierna derecha se conecta en el puerto analógico A0 del Arduino, el sensor MyoWare de la pierna izquierda se conecta en el puerto analógico A1 del Arduino. A través de dichos puertos, la señal se convierte a digital y los valores son grabados en una memoria microSD o enviados por bluetooth a la computadora. En la Figura 23 se muestran las conexiones del sensor MyoWare – Arduino – Micro SD y Bluetooth y en la Figura 24 se muestra la foto donde se colocan los electrodos y el sensor muscular MyoWare.






Figura 23 Conexiones Arduino, Sensores MyoWare, Bluetooth y MicroSD



Figura 24 Colocación de los electrodos y el Sensor MyoWare

Con el comando  $EMG0 = analogRead(A0)$  y  $EMG1 = analogRead(A1)$  el Arduino lee el puerto analógico A0 y A1, guarda los valores en las variables  $EMG0$  y  $EMG1$ , que representan la pierna derecha e izquierda, respectivamente.

### 3.5. MUESTREO Y CLASIFICACIÓN DE SEÑALES

Para realizar el muestreo y clasificación de señales se conectó al Arduino un lector de memoria MicroSD [36] (Figura 25) en los puertos digitales. El programa que se

desarrolló se cargó al Arduino y es el encargado de comunicarse por bluetooth con la computadora para iniciar el muestreo y la clasificación de las señales. En la memoria se guardan los archivos que contienen los valores de las señales que se toman de las muestras. Los archivos se extraen en formato de texto; el nombre del archivo se compone de el número de día del mes, hora, minutos, segundos en que se inicia el muestreo y por medio de una rutina se almacena con la extensión del archivo .QUI cuando la persona está parada y quieta con el andador y .CAM cuando está caminando con el andador. Por ejemplo, para la nomenclatura 07183200.QUI, significa que la señal se extrajo el día 07 a las 18 hrs con 32 minutos y 0 segundos y que además, la persona estaba parada y quieta con el andador.




Figura 25 Lector de memoria MicroSD [36]

Con el comando `logFile = SD.open(Archivo, FILE_WRITE)` se crea el archivo donde se guardan los valores de las señales y el comando `logFile.print(EMG0)` guarda los valores en el archivo. Por medio de un módulo Bluetooth HC-06 [37] (Figura 26) conectado al puerto serial del Arduino y el programa `Andando.py`, desarrollado en PyThon (Figura 27) se realiza la comunicación entre la computadora y el Arduino, para realizar el muestreo y la clasificación de las señales.



Figura 26 Módulo Bluetooth HC-06 [47]



Figura 27 Interfaz de programa Andando.Py

Para iniciar el muestro y la clasificación de las señales mioelectricas del músculo recto femoral se realizan los siguientes pasos:

- a. Realizar limpieza del área del músculo recto femoral de la pierna derecha y la pierna izquierda, donde se colocan los electrodos.
- b. Conectar el sensor muscular MyoWare en el músculo y encender el circuito Arduino.
- c. Iniciar el programa Andando.Py en la computadora, conectar por Bluetooth el puerto COM4.
- d. Indicar al paciente que se mantenga de pie, quieto y sujetándose del andador y seleccionar la opción Quieto en el programa Andando.Py, automáticamente el Arduino comenzará a grabar las señales en un archivo .QUI, cuando pase el número de minutos deseados para el muestreo seleccionar la opción Alto. En este caso el muestreo se realizó por 3 minutos.
- e. Indicar al paciente que inicie la marcha y se mantenga caminando por un tiempo determinado (en este caso 3 minutos), inmediatamente en el programa Andando.Py seleccionar la opción Caminar, el Arduino comenzará a grabar las señales en un archivo .CAM, cuando pasen los 3 minutos deseados seleccionar la opción Alto.

- f. Repetir los pasos d) y e) todas las veces posibles para poder tomar una gran cantidad de muestras que se utilizarán para el entrenamiento de la red neuronal.

En la Figura 28, se muestra el contenido de un archivo de texto con los valores de las señales, separados por comas. La primera columna corresponde al tiempo en milisegundos que se tomó la muestra de la señal, la segunda columna corresponde al valor de la señal EMG0 (pierna derecha) que se obtuvo en ese tiempo y la tercera columna corresponde al valor de la señal EMG1 (pierna izquierda).




Figura 28 Archivo texto con valores de las señales

### 3.6. ANÁLISIS DE SEÑALES

Con el programa EMGs\_ANN.ipynb se grafican las señales EMG que se obtienen de las dos piernas cuando está caminando y cuando está quieto. En la Figura 29 se muestran los valores de las señales cuando está quieto, se observa que los valores en algún momento se mantienen debajo de 200 otros aumentan, esto sucede normalmente cuando está haciendo equilibrio.




Figura 29 Señales EMG Cuando está quieto

Se analizaron las señales que se obtuvieron cuando estuvo caminando, las fuerzas que se aplican en los músculos al caminar varían dependiendo de las condiciones físicas que se encuentre la persona.

En la Figura 30 se grafican los valores de las señales EMG de las dos piernas cuando está caminando en línea recta los primeros minutos del muestreo, se observa que aplica fuerzas que generan voltajes arriba de 250, 300 hasta 600, 700 mv.




Figura 30 Señales EMG Cuando está caminando en línea recta

En la Figura 31 se grafican los valores de las señales EMG de las dos piernas cuando está caminando en círculos, en la Figura 31a se observa que cuando da vuelta a la izquierda (línea naranja) aplica más fuerza en la pierna derecha (línea

azul) y en la Figura 31b cuando da vuelta a la derecha (línea azul) aplica más fuerza en la pierna izquierda (línea naranja).




Figura 31 Señales EMG cuando está caminando en círculos

En la Figura 32 se muestra la gráfica de los valores de las señales que se obtuvieron cuando está caminando ya cansado (después de varios minutos del muestreo). En la figura se puede observar la secuencia de variaciones de valores de las señales EMG (línea azul pierna derecha, línea naranja pierna izquierda), igual que cuando camina en línea recta aumenta el valor de la señal cuando levanta una pierna y disminuye la otra, pero a diferencia de caminar cuando no está cansado, los músculos ya están más relajados y aplica menos fuerza al levantar las piernas al caminar, los valores no rebasan los 400 mv.




Figura 32 Señales EMG cuando está caminando cansado

### 3.7. ESTUDIO DE LA BIOMECÁNICA DE LA MARCHA

La biomecánica de la marcha describe el comportamiento de los diferentes elementos que conforman la pierna humana en conjunto durante la marcha normal, el ciclo de la marcha comienza cuando un pie hace contacto con el suelo y termina con el siguiente contacto del mismo pie, la distancia entre estos dos puntos de contacto con el suelo se le llama un paso completo [32].

El ciclo de la marcha se divide en dos fases, la fase de apoyo y la fase de balanceo (Figura 33). Una pierna está en fase de apoyo cuando está en contacto con el suelo y después está en fase de balanceo cuando no contacta con el suelo. Estas dos fases se van alternando de una pierna a la otra durante la marcha. En un paso completo, el apoyo sencillo se refiere al periodo cuando sólo una pierna está en contacto con el suelo.




Figura 33 Representación de los principales componentes de la marcha

En este proyecto es importante conocer la secuencia de movimientos de las piernas al caminar y el tiempo que toma cada una en las fases del ciclo de la marcha, para determinar el tiempo promedio de muestreo de las señales mioeléctricas que representan un paso.

### 3.8. MODELADO CON UNA RED NEURONAL ARTIFICIAL

Las redes neuronales artificiales (*Artificial Neural Networks*) y Máquinas de soporte vectorial (*Support Vector Machines*) son dos estrategias populares para la clasificación y el aprendizaje automático supervisado. Las ANN, como método para

implementar un clasificador de múltiples clases han mostrado ser efectivas en aplicaciones diversas. Se han utilizado eficazmente para determinación de patrones de comportamiento, detección de condiciones específicas, fallas y otros aspectos. Una máquina vectorial de soporte (SVM) es un modelo capaz de realizar clasificación lineal o no lineal, regresión e incluso detección de valores atípicos. Las SVM son especialmente adecuadas para la clasificación de conjuntos de datos complejos, pero de tamaño pequeño o mediano [35].

Con base a esta información se optó por utilizar una red neuronal artificial para realizar la clasificación de las señales que se obtuvieron de la persona con discapacidad e identificar la intención de caminar.

		Entradas																				y		
		Pierna Derecha										Pierna Izquierda												
		1	2	3	4	5	...	496	497	498	499	500	501	502	503	504	505	...	996	997	998		999	1000
Muestras	1	82	84	83	84	82	...	62	62	64	67	66	147	146	146	144	145	...	135	134	135	135	136	CAM
	2	96	96	97	95	95	...	85	87	87	88	88	148	148	148	147	147	...	125	124	124	126	124	CAM
	3	67	67	67	67	67	...	95	96	97	96	96	135	135	135	134	134	...	101	101	101	102	100	CAM
	4	88	88	89	87	87	...	130	129	130	131	132	133	124	124	123	122	...	91	92	91	91	91	CAM
	5	96	97	96	98	101	...	141	140	140	142	139	100	100	100	100	99	...	89	87	87	87	85	CAM
	6	136	141	143	144	143	...	152	152	157	154	154	91	91	90	91	89	...	80	80	79	77	79	CAM
	7	...																						...
	343	49	44	43	43	44	...	46	47	46	46	47	94	78	80	78	78	...	84	84	83	84	84	QUI
	344	41	42	42	42	42	...	51	49	50	51	51	73	75	76	73	75	...	81	81	81	82	81	QUI
	345	45	45	47	45	45	...	46	48	49	48	48	83	84	84	84	84	...	86	85	85	85	85	QUI
346	51	51	51	52	52	...	44	42	44	44	44	81	81	81	81	81	...	85	83	83	84	81	QUI	

a) Matriz de muestras x

b) Etiquetas

Figura 34 Matriz de muestras y etiquetas para el entrenamiento de la red neuronal

En la Figura 34 se muestra la matriz de los datos (señales EMG) de  $n$  renglones (muestras) por 1000 columnas (entradas) y un vector  $y$  de  $n$  valores que son las etiquetas de los datos que se utilizaron para el entrenamiento de la red neuronal. Las entradas 1 a 500 corresponden a los valores de las señales de la pierna derecha y los valores de las entradas 501 a 1000 corresponden a los valores de las señales de la pierna izquierda. Cada muestra (renglón) está etiquetada con el valor del vector. Por ejemplo, el renglón 1 de la matriz tiene las entradas que corresponden



a los valores de las señales de la pierna derecha y la pierna izquierda cuando está caminando, como se aprecia en el vector de etiqueta (vector  $y$ , inciso b). El renglón 346 de la matriz tiene las entradas que corresponden a los valores de las señales de las piernas cuando la persona esta quieta.

### 3.8.1 ENTRENAMIENTO DE RED NEURONAL ARTIFICIAL

El entrenamiento fue de tipo supervisado, el cual consiste en presentar un conjunto de entrenamiento a la RNA, encontrar la salida de la red y ajustar los pesos sinápticos para que la salida actual se aproxime a las etiquetas deseadas y definidas a priori. Para realizar el entrenamiento de la RNA se utilizó la técnica de validación cruzada o *cross-validation*. En *scikit-learn*, se hace una división aleatoria en entrenamiento y conjuntos de pruebas se puede calcular rápidamente con la función de ayuda *train\_test\_split*. De acuerdo con [31], normalmente de todo el conjunto de entrenamiento se emplea aproximadamente un 80% de los patrones para entrenar y un 20% como conjunto de pruebas. El proceso de validación cruzada es repetido durante  $k = 10$  iteraciones, recomienda [34].

La clase `MLPClassifier` de la librería `sklearn.neural_network` implementa un algoritmo de perceptrón multicapa (MLP) que se entrena usando `Backpropagation`. MLP entrena en dos matrices: matriz  $X$  de tamaño ( $n$  muestras,  $m$  entradas), que contiene las muestras de entrenamiento representadas como vectores de características de punto flotante y matriz  $y$  de tamaño ( $n$  muestras), que contiene los valores objetivo (etiquetas de clase) para las muestras de entrenamiento. La función de activación que utiliza por default la clase `MLPClassifier` es `relu`. `ReLU` (Unidad lineal rectificadora) es una función de activación que permite un entrenamiento más rápido de las redes neuronales artificiales, permiten que todos los valores positivos pasen sin cambios y los valores negativos los ponen en cero [14].

Una forma de evaluar el rendimiento de un clasificador es con la matriz de confusión. Se construye un modelo de clasificación que permita discriminar entre dos clases diferentes [34]. La primera clase Caminar, se denomina clase positiva ( $P$ ). La otra clase Quieto, se asigna clase negativa ( $N$ ). Cuando se aplica el modelo de clasificación a los datos previamente etiquetados, se puede ver fácilmente cómo etiqueta los diferentes ejemplos el clasificador. Sólo existen cuatro posibilidades, que puede representar en una matriz de confusión. La Figura 35 muestra un ejemplo de la matriz de confusión para un problema de clasificación binaria.

		Predicción	
		Positivos	Negativos
Clase Real	Positivos	Verdaderos Positivos	Falsos Negativos
	Negativos	Falsos Positivos	Verdaderos Negativos

Figura 35 Matriz de confusión para un problema de clasificación binaria

La Figura 36 muestra la matriz de confusión con los resultados de la evaluación de las pruebas realizadas, en la parte de arriba de la figura están las clases Caminando con 436 muestras y Quieto con 145 muestras que ya se conocen, en la izquierda se muestran las entradas de la red neuronal, se hacen las pruebas mandando 436 muestras como caminando (positivos) y 145 muestras como quieto (verdaderos negativos), la red neuronal identifica 428 correctas como caminando (verdaderos positivos), 8 incorrectas como quieto (falsos negativos), 137 correctas como quieto (verdaderos negativos) y 8 incorrectas como caminando (falsos positivos).

		Clasificador		
		Caminando	Quieto	% Acierto
Datos de entrada	Caminando	428	8	98.17
	Quieto	8	137	94.48

Figura 36 Matriz de confusión de la red neuronal

En el contexto de las redes neuronales el aprendizaje puede ser visto como el proceso de ajuste de los parámetros libres de la red. Partiendo de un conjunto de pesos sinápticos aleatorios, el proceso de aprendizaje busca un conjunto de pesos que permitan a la red desarrollar correctamente una determinada tarea. El proceso de aprendizaje es un proceso iterativo, en el cual se va refinando la solución hasta alcanzar un nivel de operación suficientemente bueno [38]. En este proyecto la idea es detectar la intención de caminar por lo que se esperaba un porcentaje de acierto mínimo del 80%, durante el proceso de entrenamiento se obtuvieron resultados arriba del 90%, se realizaron algunas modificaciones en la red neuronal (250 entradas, 3 capas ocultas de 80 neuronas cada una), logrando un promedio de exactitud 98.30% caminando y 96.54% estando quieto con una desviación estándar de 0.60 Caminando y 1.46 estando quieto.

### 3.8.2 ALMACENAMIENTO DEL MODELO

Después de entrenar el modelo, es necesario tener una manera de conservar el modelo para poder usarlo con nuevos datos sin tener que volver a entrenar. El modelo se guardó en *scikit-learn* con el comando *joblib.dump(Modelo)*.

Para realizar la evaluación de la red neuronal con nuevos datos se utilizó el comando *joblib.load(Modelo)* para cargarlo y ejecutarlo.

# CAPÍTULO 4

## **RESULTADOS EXPERIMENTALES**

---

Con la finalidad de la metodología de adquisición y clasificación de señales mioeléctricas, se extrajeron señales de una persona que tiene rigidez en los músculos de las piernas, lo que provoca que dé los pasos cortos, lentos y no doble lo suficiente la rodilla para poder dar pasos más largos y/o subir escaleras y rampas. Con esta metodología se logró identificar la intensidad de caminar, mediante las señales mioeléctricas emitidas por los músculos de las piernas. En este capítulo se muestran las diferentes pruebas que se realizaron para caracterizar las señales.

La sección 4.1 muestra la captura de señales EMG, caminar en línea recta, caminar en círculos, caminar cansado. La sección 4.2 muestra el entrenamiento de la red neuronal y la sección 4.3 identifica la intensidad de caminar de la persona con discapacidad.

### **4.1. SELECCIÓN DE DISPOSITIVOS PARA EXTRACCIÓN DE SEÑALES**

Se realizó la compra del Electrodo Superficial “Adulto Medi-trace Serie 200 Ecg Desechable C/100” y dos sensores MyoWare, para ser utilizados en la adquisición de señales mioeléctricas.

### **4.2. IDENTIFICACIÓN DEL MÚSCULO**

Se realizó la limpieza del área del músculo recto femoral, donde se colocaron los electrodos. Posicionando los electrodos con base en la normatividad de SENIAM [18].

### **4.3. EXTRACCIÓN DE SEÑALES CONVERSIÓN ANALÓGICO - DIGITAL**

Se realizó la compra de la tarjeta Arduino Nano, un lector de memorias MicroSd, un módulo Bluetooth Hc-06 para Arduino, se realizaron las conexiones de los circuitos de acuerdo con lo especificado en la sección 3.4.

### **4.4. MUESTREO Y CLASIFICACIÓN DE SEÑALES**

Durante el proceso de muestreo y clasificación de señales se extrajo un total de 1,119,706 señales de cada pierna (22 minutos aproximadamente), que fueron suficientes para realizar las pruebas de entrenamiento y validación del modelo de la red neuronal. Se extrajeron 2 clases de señales 113,753 (3 minutos aproximadamente) estando quieto, 455,015 (9 minutos aproximadamente) caminando, las cuáles se muestran en la sección 4.5 Análisis de señales.

### **4.5. ANÁLISIS DE SEÑALES**

En el análisis de las señales que se obtuvieron en el muestreo y clasificación se observaron ciertas características, los valores varían dependiendo de la condición física que se encuentre, tenso, relajado, cansado, también cambian cuando camina en línea recta y cuando da vueltas en círculo, en la sección 4.5.1 y 4.5.2 se detallan dichas características.

#### **4.5.1 ESTAR QUIETO**

Se extrajeron 113,753 (3 minutos aproximadamente) señales del músculo de cada pierna mientras la persona se mantuvo una posición de pie y en reposo, las cuáles se gravaron en un archivo de texto como clase quieto, para ello el archivo fue gravado con extensión QUI. En la Figura 37 se muestran cuatro gráficas donde se observan los valores de las señales que se obtuvieron cuando está quieto.




Figura 37 Gráfica Señales EMG Quieto

## 4.5.2 CAMINANDO

Durante las pruebas que se estuvieron realizando se observó que los valores de las señales mioeléctricas son diferentes cuando camina en línea recta, en círculo y cuando está cansado. Por esta razón se hicieron tres subclases las cuáles se muestran en la sección 4.5.2.1. Caminar en línea recta, 4.5.2.2 Caminar en círculos, 4.5.2.3 Caminar cansado, como se describe a continuación.

### 4.5.2.1 CAMINANDO EN LÍNEA RECTA

Se extrajeron 142,192 (3 minutos aproximadamente) señales del músculo de cada pierna mientras la persona caminó en línea recta, los valores se grabaron en un archivo texto con extensión CAM. En la Figura 38 se muestran cinco gráficas donde se observan los valores de las señales que se obtuvieron cuando está caminando en línea recta. En la figura se puede observar la secuencia de variaciones de valores de las señales EMG, cuando levanta una pierna (línea azul pierna derecha, línea naranja pierna izquierda) aplica una fuerza y aumenta el valor de la señal, pasa lo inverso en la otra pierna, disminuye fuerza que aplica y disminuye el valor de la señal. Cuando no está cansado, tiene las piernas más rígidas y aplica más fuerza, lo cual aumenta el valor de la señal a más de 400 mv.

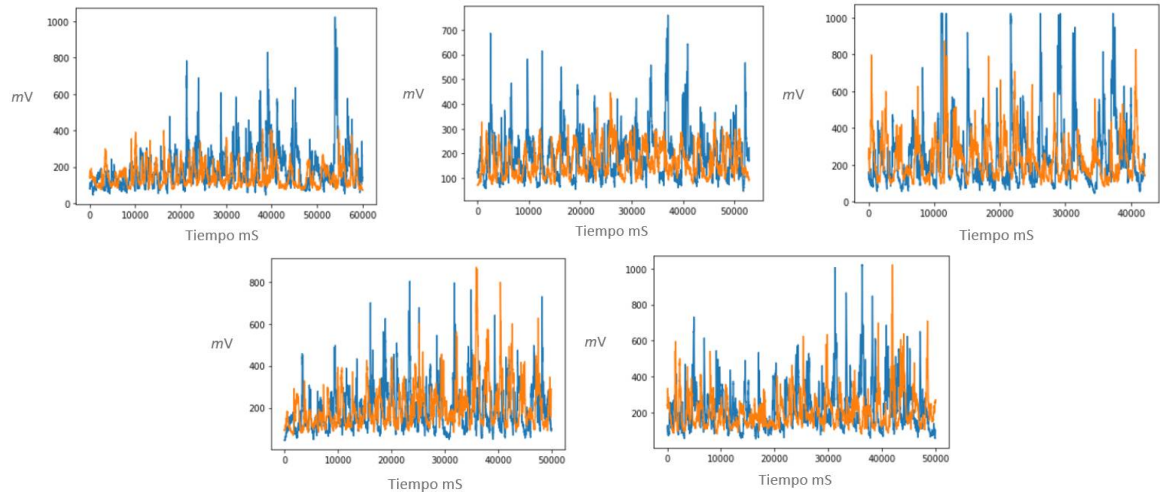


Figura 38 Señales EMG caminando en línea recta

#### 4.5.2.2 CAMINANDO EN CÍRCULOS

Se extrajeron 199,069 (4 minutos aproximadamente) señales del músculo de cada pierna mientras la persona caminaba en círculos, se grabaron los valores en un archivo texto con extensión CAM. En la Figura 39 se muestran siete gráficas donde se observan los valores de las señales que se obtuvieron cuando está caminando en círculos (línea azul pierna derecha, línea naranja pierna izquierda). En la figura se puede observar la secuencia de variaciones de valores de las señales EMG, igual que cuando camina en línea recta aumenta el valor de la señal cuando levanta una pierna y disminuye la otra, pero a diferencia de caminar en línea recta no lleva un orden ya que varía dependiendo si da vuelta a la izquierda o derecha. En las gráficas de la figura se puede ver donde aplica más fuerza en la pierna derecha (línea azul) cuando da vuelta a la derecha y cuando da vuelta a la izquierda aplica más fuerza en la pierna izquierda (línea naranja).

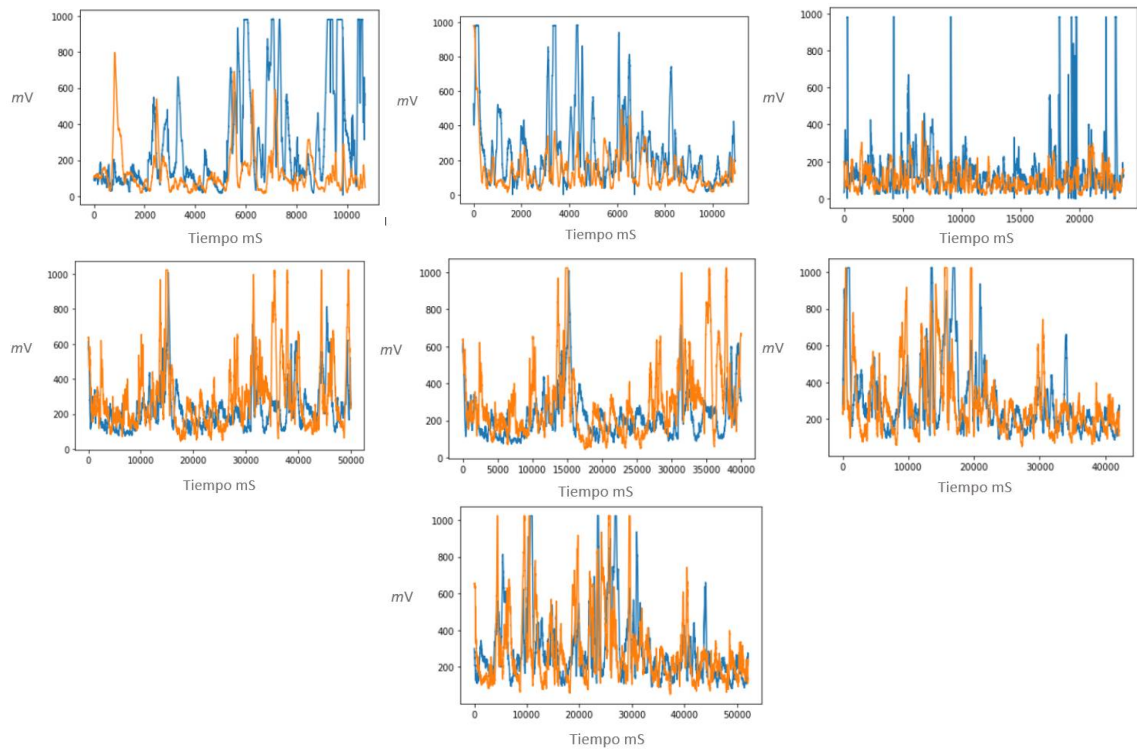


Figura 39 Señales EMG caminando en círculos

#### 4.5.2.3 CAMINANDO CANSADO

Se extrajeron 113,754 (3 minutos aproximadamente) señales del músculo de cada pierna caminando mientras la persona caminaba en un estado cansado, se grabaron los valores en un archivo texto con extensión CAM. En la Figura 40 se muestran cuatro gráficas donde se observan los valores de las señales que se obtuvieron cuando está caminando ya cansado. En la figura se puede observar la secuencia de variaciones de valores de las señales EMG (línea azul pierna derecha, línea naranja pierna izquierda), igual que cuando camina en línea recta aumenta el valor de la señal cuando levanta una pierna y disminuye la otra, pero a diferencia de caminar cuando no está cansado, los músculos ya están más relajados y aplica menos fuerza al levantar las piernas al caminar, los valores no rebasan los 400 mv.



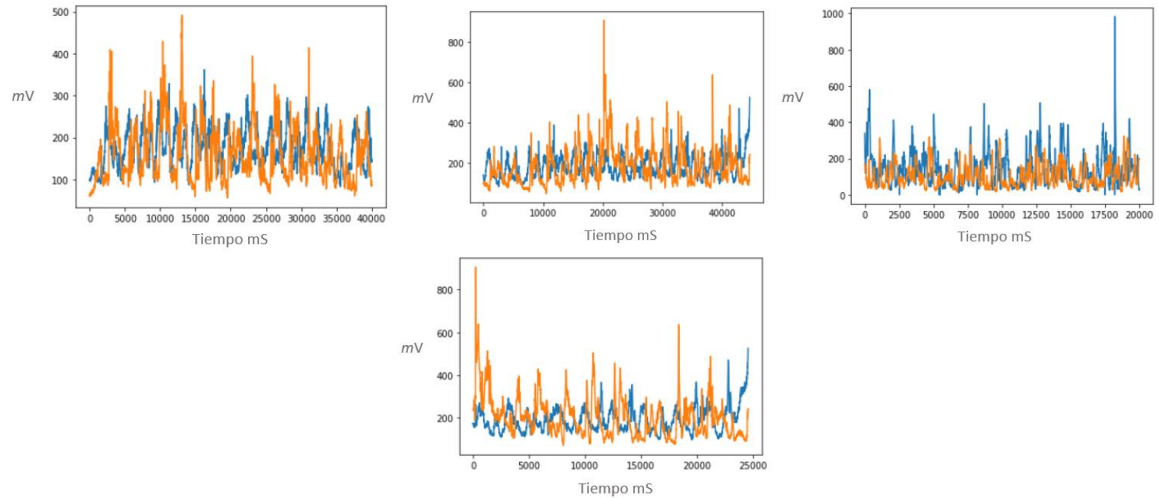


Figura 40 Señales EMG caminando cansado

#### 4.6. BIOMECÁNICA DE LA MARCHA

De acuerdo a la biomecánica de la marcha, el tiempo promedio que tarda en dar un paso de la persona con discapacidad que se está estudiando es 2 segundos por un paso completo y 1 segundo en mover una pierna para dar un paso. Lo anterior ayudó a determinar que la matriz de características que se utiliza en la red neuronal debe ser de 500 muestras de la señal, lo que equivale a 500 milisegundos de él tiempo de muestreo, aproximadamente.

#### 4.7. MODELADO CON UNA RED NEURONAL ARTIFICIAL

La Figura 41 muestra la matriz de confusión con los resultados de la evaluación de las pruebas realizadas, en la parte de arriba de la figura están las clases Caminando con 436 muestras y Quieto con 145 muestras que ya se conocen, en la izquierda se muestran las entradas de la red neuronal. Se observa que de las 436 señales clasificadas como caminando, la red neuronal identifica 428 correctas como caminando y 8 como quieto. Por otra parte, de las 145 señales que corresponden a la clase quieto, la red neuronal logró identificar 137 de forma correcta y 8 incorrecta. De tal forma que se puede decir que la red obtuvo un 98.17% de acierto en la clase caminando y un 94% para la clase Quieto.

Se realizaron varias pruebas de entrenamiento para la red neuronal, modificando la cantidad de capas ocultas, la cantidad de neuronas en cada capa, como se muestra a continuación.

		Clasificador		
		Caminando	Quieto	% Acierto
Datos de entrada	Caminando	428	8	98.17
	Quieto	8	137	94.48

Figura 41 Matriz de Confusión de la red neuronal

La Tabla 8 muestra los resultados del entrenamiento de la red neuronal con 3 capas ocultas y 80 neuronas cada una, se obtuvo un promedio de exactitud 98.25% caminando y 96.3% estando quieto con una desviación estándar de 0.83 Caminando y 1.01 estando quieto. En la tabla se muestran marcados de color celeste los mejores resultados de las pruebas.

Tabla 8 Entrenamiento de la red neuronal con 3 capas ocultas de 80 neuronas cada una

Prueba	Aciertos		%	
	Caminando	Quieto	Caminando	Quieto
1	344	102	98.85	95.33
2	341	105	97.99	98.13
3	344	105	98.85	98.13
4	335	104	96.26	97.20
5	341	103	97.99	96.26
6	345	104	99.14	97.20
7	341	103	97.99	96.26
8	343	104	98.56	97.20
9	344	102	98.85	95.33
10	341	103	97.99	96.26
Desviación Estándar			0.83	1.01
Promedio Exactitud			98.25	96.73

La Tabla 9 muestra los resultados del entrenamiento de la red neuronal con una capa oculta de 80 neuronas, se obtuvo un promedio de exactitud 96.41% caminando y 98.32% estando quieto con una desviación estándar de 0.76 Caminando y 0.59 estando quieto. En la tabla se muestran marcados de color celeste los mejores resultados de las pruebas.

Tabla 9 Entrenamiento de la red neuronal con una capa ocultas de 80 neuronas

Prueba	Aciertos		%	
	Caminando	Quieto	Caminando	Quieto
1	335	105	96.26	98.13
2	333	105	95.69	98.13
3	333	105	95.69	98.13
4	333	106	95.69	99.07
5	337	105	96.84	98.13
6	333	105	95.69	98.13
7	339	105	97.41	98.13
8	335	106	96.26	99.07
9	337	106	96.84	99.07
10	340	104	97.70	97.20
Desviación Estándar			0.76	0.59
Promedio Exactitud			96.41	98.32

La Tabla 10 muestra los resultados del entrenamiento de la red neuronal con dos capas ocultas de 50 neuronas cada una, se obtuvo un promedio de exactitud 98.02% caminando y 96.64% estando quieto con una desviación estándar de 0.93 Caminando y 1.60 estando quieto. En la tabla se muestran marcados de color celeste los mejores resultados de las pruebas.

Tabla 10 Entrenamiento de la red neuronal con 2 capas ocultas de 50 neuronas cada una

Prueba	Aciertos		%	
	Caminando	Quieto	Caminando	Quieto
1	345	101	99.14	94.39
2	338	105	97.13	98.13
3	343	103	98.56	96.26
4	337	104	96.84	97.20
5	343	102	98.56	95.33

6	343	104	98.56	97.20
7	335	106	96.26	99.07
8	342	105	98.28	98.13
9	343	103	98.56	96.26
10	342	101	98.28	94.39
Desviación Estándar			0.93	1.60
Promedio Exactitud			98.02	96.64

Se realizó otra prueba de entrenamiento modificando la matriz de entrada, donde se borraron las 250 columnas nones de esa matriz, con la intención de reducir la cantidad de muestras y reducir el tiempo de respuesta de la red neuronal. En la Figura 42 se muestra un ejemplo de cómo se modificó la matriz de entrada a la red neuronal.

```
[[ 0  1  2  3  4  5  6  7  8  9 10 11 12 13 14 15 16 17 18 19]
 [20 21 22 23 24 25 26 27 28 29 30 31 32 33 34 35 36 37 38 39]
 [40 41 42 43 44 45 46 47 48 49 50 51 52 53 54 55 56 57 58 59]
 [60 61 62 63 64 65 66 67 68 69 70 71 72 73 74 75 76 77 78 79]]
[[ 1  3  5  7  9 11 13 15 17 19]
 [21 23 25 27 29 31 33 35 37 39]
 [41 43 45 47 49 51 53 55 57 59]
 [61 63 65 67 69 71 73 75 77 79]]
```

Figura 42 Ejemplo matriz de entrada sin las columnas nones

Los resultados con la matriz de entrada modificada, con tres capas ocultas de 80 neuronas cada una, se muestran en la Tabla 11, que se obtuvo un promedio de exactitud 98.30% caminando y 96.54% estando quieto con una desviación estándar de 0.60 Caminando y 1.46 estando quieto. En la tabla se muestran marcados de color celeste los mejores resultados de las pruebas.

Tabla 11 Entrenamiento de la red neuronal con 3 capas ocultas de 80 neuronas cada una, con matriz de entrada modificada

Prueba	Aciertos		%	
	Caminando	Quieto	Caminando	Quieto
1	343	102	98.56	95.33
2	339	104	97.41	97.20

3	341	104	97.99	97.20
4	340	103	97.70	96.26
5	341	105	97.99	98.13
6	343	105	98.56	98.13
7	341	105	97.99	98.13
8	346	101	99.43	94.39
9	344	101	98.85	94.39
10	343	103	98.56	96.26
Desviación Estándar			0.60	1.46
Promedio Exactitud			98.30	96.54

De acuerdo con el entrenamiento de la red neuronal se seleccionó el modelo con los mejores resultados, la red neuronal de 3 capas ocultas de 80 neuronas cada una con 500 entradas, 250 pierna derecha y 250 pierna izquierda, donde sólo se toman los valores de las columnas nones. Con la intención de reducir el volumen de los datos y con ello el tiempo de procesamiento.

#### 4.7.1 EVALUACIÓN DEL MODELO

Para realizar la evaluación de la red neuronal se extrajeron 128,212 (3 minutos aproximadamente) nuevas señales del músculo de cada pierna caminando y 64,731 (1 minuto y medio aproximadamente) cuando está de pie en reposo, se grabaron los valores en un archivo texto con extensión CAM y QUI. Se realizó la evaluación de la red neuronal entrenada con los nuevos valores de las señales obteniendo un 98% de acierto cuando camina y un 95% cuando está quieto.

La Figura 43 muestra la matriz de confusión con los resultados de la evaluación. El primer renglón muestra la clase caminando con 505 casos clasificados de forma correcta y falló en 8 casos, en el segundo renglón se observa que, de las 259 señales de la clase quieto, 247 fueron clasificadas de forma correcta y solo se falló en 12 casos. Lo cual implica que la red tuvo un porcentaje de acierto del 98% para la clase caminando y de un 95% para la clase quieto.

		Clasificador		
		Caminando (Positivos)	Quieto (Negativos)	% Acierto
Datos de entrada	Caminando (Positivos)	<b>VP</b> 505	<b>FN</b> 8	98.44
	Quieto (Negativos)	<b>FP</b> 12	<b>VN</b> 247	95.37

Figura 43 Matriz de Confusión de la red neuronal después del entrenamiento

# CAPÍTULO 5

## **CONCLUSIONES Y TRABAJO FUTURO**

Las señales mioeléctricas son emitidas por los músculos del cuerpo humano cuando realizan un movimiento, proporcionando información que puede ser utilizada para identificar los patrones de movimiento, desarrollar aplicaciones que pueden servir de base para el diseño y construcción de mecanismos que pueden ser utilizados para las terapias, ayudar a mejorar o corregir algunos movimientos, entre otros [33].

### **5.1. CONCLUSIONES**

Durante el desarrollo de esta metodología, se utilizó la tarjeta Arduino que es la encargada de tomar la señal del sensor muscular MyoWare. Las señales mioeléctricas se obtienen del músculo recto femoral que es el que más interviene en el movimiento de las piernas al caminar. Con la tarjeta Arduino y el sensor MyoWare se realizó el muestreo y clasificación de las señales mioeléctricas del músculo recto femoral. Durante el análisis de las señales se observó que varían dependiendo de la actividad que realice, estar quieto y parado sujetándose del andador, cuando está caminando en línea recta o caminando en círculos, también varían las señales cuando ya está cansado. Se obtuvo información sobre biomecánica de la marcha que describe la secuencia de movimientos de las piernas al caminar, también se obtuvo información donde comentan que en promedio el ser humano tarda un segundo en dar un paso, lo cual sirvió para determinar la cantidad de señales que se utilizaron como entradas a la red neuronal. Se realizó el entrenamiento y evaluación del modelo de la red neuronal, y se obtuvieron mejores tasas de acierto utilizando 3 capas ocultas y 80 neuronas cada una.

Para detectar la intención de caminar de la persona se extrajeron señales mioeléctricas del músculo recto femoral de la pierna izquierda y la pierna derecha, en las siguientes condiciones:

- Estar quieto: se extrajeron señales del músculo de cada pierna la persona mantuvo una posición de pie y en reposo, se grabaron en un archivo de texto como clase quieto.
- Caminando en línea recta: se extrajeron señales del músculo de cada pierna mientras la persona caminó en línea recta, los valores se grabaron en un archivo texto con extensión CAM. Cuando la persona da un paso, provoca una variación de voltaje (sube) y cuando la pierna vuelve a detenerse, baja el voltaje, mientras pasa el proceso inverso con la otra pierna.
- Caminando en círculos: se extrajeron señales del músculo de cada pierna mientras la persona caminaba en círculos, se grabaron los valores en un archivo texto con extensión CAM. Pero a diferencia de caminar en línea recta no lleva un orden ya que los voltajes aumentan más dependiendo si da vuelta a la izquierda o derecha.
- Caminando cansado: se extrajeron señales del músculo de cada pierna caminando mientras la persona caminaba en un estado cansado, se grabaron los valores en un archivo texto con extensión CAM. pero a diferencia de caminar cuando no está cansado, los músculos ya están más relajados y aplica menos fuerza al levantar las piernas al caminar, los valores no rebasan los 400 *mv*.

Con las señales que se extrajeron del músculo se realizó el entrenamiento de la red neuronal. Se utilizó el 80% para el entrenamiento y el 20% para realizar las pruebas, logrando un porcentaje de acierto del 98% cuando está caminando y un 94% cuando está quieto. Después de entrenar el modelo, se guardó en *scikit-learn* con el comando *joblib.dump(Modelo)*, para poder usarlo con nuevos datos sin tener que volver a entrenar.



Con el modelo que se guardó se realizó la evaluación de la red neuronal, se extrajeron 128,212, nuevas señales del músculo de cada pierna caminando y 64,731 cuando está de pie en reposo, se grabaron los valores en un archivo texto con extensión CAM y QUI. Se realizó la evaluación de la red neuronal entrenada con los nuevos valores de las señales obteniendo un 98% de acierto cuando camina y un 95% cuando está quieto.

## **5.2. TRABAJOS FUTUROS**

Dado que el desarrollo de la metodología requirió de la implementación de una herramienta de adquisición y clasificación de señales mioeléctricas se recomienda mejorar el desempeño de la herramienta desarrollada como se menciona a continuación:

- Reducir el tiempo de muestreo, actualmente es de 1 milisegundo y se demostró que usando las columnas nones de la matriz de entrada tuvo mejoras en los aciertos, hacer pruebas de tiempo de muestreo hasta reducirlo a un tiempo que cumpla con más del 95% de aciertos.
- Continuar con el proyecto para que identifique en tiempo real la intensidad de caminar.
- Incluir más clases de señales que se puedan utilizar para identificar cuando se quiere sentar, cuando se quiere parar.

Como posibles aplicaciones futuras de este trabajo de detección de intensidad de caminar se determinaron las siguientes:

- Diseñar y construir una órtesis robótica, para que los pacientes con estas características puedan utilizarla y realizar terapias físicas de doblar las rodillas y relajar los músculos en base a las señales mioeléctricas de las piernas y las redes neuronales.
- Diseñar y construir una órtesis robótica (exoesqueleto), con el que se pueda caminar más rápido y doblar las rodillas para subir escalones y rampas.

## REFERENCIAS BIBLIOGRÁFICAS

- [1] Jarmey, Chris, Atlas conciso de los músculos Editorial Paidotribo, Badalona, España, 2008.
- [2] Instituto Nacional de Estadística y Geografía (INEGI), “La discapacidad en México, datos al 2014”, Disponible en línea: [http://internet.contenidos.inegi.org.mx/contenidos/Productos/prod\\_serv/contenidos/espanol/bvinegi/productos/nueva\\_estruc/702825090203.pdf](http://internet.contenidos.inegi.org.mx/contenidos/Productos/prod_serv/contenidos/espanol/bvinegi/productos/nueva_estruc/702825090203.pdf).
- [3] Lyn Weiss, Julie Silver, Jay Weiss, EASY EMG, Butterworth-Heinemann, Lewiston, NY, U.S.A, 2004.
- [4] Wahyu Caesarendra, Syahara U Leksona, Khusnul A Mustaqima, Andri R Winotob, “A Classification Method of Hand EMG Signals Based on Principal Component Analysis and Artificial Neural Network,” Mechanical Engineering Department, Faculty of Engineering, Diponegoro University, Semarang, Indonesia, Department of Orthopaedic and Traumatology School of Medicine, Diponegoro University Semarang 50275, Indonesia, agosto. 2016.
- [5] Zhen Zhang, Kuo Yang, Jinwu Qian, Lunwei Zhang, “Real-Time Surface EMG Pattern Recognition for Hand Gestures Based on an Artificial Neural Network,” Journals Sensors, 19(14): 3170, DOI:10.3390/s19143170.
- [6] Rios M., MANUAL de Educación Física adaptada al alumnado con discapacidad, Barcelona España, Editorial Paidotribo, 2003.
- [7] Hussein S.E., Granat M.H., “Intention detection using a neuro-fuzzy EMG classifier,” International Conference of the IEEE Engineering in Medicine and Biology Magazine, pp. 123-129, 2002.
- [8] Cameron J. and Skofronick J., Medical Physics: Physics of the Body, Wiley, Aurora, IL, USA. 1978.

- [9] Sanromá M., ASPACE Asociación Sevillana de Parálisis Cerebral, "Principales tipos de Parálisis Cerebral," febrero 2018. Disponible en línea: [http://aspacesevilla.org/index.php?option=com\\_content&view=article&id=125&Itemid=119](http://aspacesevilla.org/index.php?option=com_content&view=article&id=125&Itemid=119).
- [10] Konrad P., The ABC of EMG: A Practical Introduction to Kinesiological Electromyography, Noraxon INC. USA, 2005.
- [11] Isasi P., Galvan I., "Redes Neuronales Artificiales, un enfoque práctico." PEARSON, 2006.
- [12] Hilera, José R. y Martínez, Víctor J. "Redes Neuronales Artificiales Fundamentos, modelos y aplicaciones ". Alfaomega Ra-Ma, Madrid, España, 2000.
- [13] Graupe D., "Principles of Artificial Neural Networks," World Scietifics, 2007.
- [14] Géron A., "Hands-On Machine Learning with Scikit-Learn & TensorFlow", O'Reilly, Gravenstein Highway North, Sebastopol, CA, 2017.
- [15] Merletti R., Parker P., Electromyography: Physiology, Engineering, and Noninvasive Applications, John Wiley & Sons, Inc., Hoboken, New Jersey, 2004.
- [16] Guyton A. C. y Hall J. E., Textbook of Medical Physiology, 11.a ed. Elsevier Saunders, Philadelphia, 2006.
- [17] Merletti R., Electromyography-Physiology, Engineering and Noninvasive Applications. John Wiley and Sons, 2004.
- [18] Merletti R., Rau G. and Disselhorst-Klug C., "SENIAM, Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles," Febrero 2018. Disponible en línea: <http://seniam.org/>.

- [19] Newman M. "Biopotential Electrodes." The Biomedical Engineering Handbook: 2ª Edición. Broken Sound Parkway FL, USA, 2006.
- [20] Kaminski B., Advancer Technologies, "MyoWare™ Muscle Sensor," Marzo 2018. Disponible en línea: [http://www.advancertechnologies.com/p/shop\\_3.html](http://www.advancertechnologies.com/p/shop_3.html).
- [21] Bolton W., Mecatrónica: Sistemas de control electrónico en ingeniería mecánica y eléctrica, 2ª Edición, Alfaomega, 2005.
- [22] Barragán H., Arduino, Febrero 2018. Disponible en línea: <https://www.arduino.cc/en/Guide/Introduction#>.
- [23] Costa Á., Itkonen M., Yamasaki H., Alnajjar F., Shimoda S., "Importance of muscle selection for EMG signal analysis during upper limb rehabilitation of stroke patients," International Conference of the IEEE Engineering in Medicine and Biology Society, pp. 2510-2513, 2017.
- [24] Shabani A., Mahjoob M., "Bio-signal interface for knee rehabilitation robot utilizing EMG signals of thigh muscles," International Conference on Robotics and Mechatronics, pp. 228 – 233, 2016.
- [25] Calderon C. A., Jaramillo L., Zuñiga J., Hernandez W., and Rivas F., "A Neural Network embedded system for realtime identification of EMG signals," ICA-ACCA 2018, October 17-19, 2018, Greater Concepción, Chile.
- [26] Rodríguez E., Dorantes G., Mendoza M., "Clasificación de EMG a través de Índices Lineales y No Lineales por Medio de Redes Neuronales Artificiales", Memorias del XXXVIII Congreso Nacional de Ingeniería Biomédica. Mazatlán, Sin., México, pp. 386-389, Octubre 2015.
- [27] Matsumura Y., Mitsukura Y., Fukumi M., Akamatsu N., Yamamoto Y. and Nakaura K., "Recognition of EMG signal patterns by Neural NetWorks",

Proceedings of the 9th International Conference on Neural Information Processing, 2002. ICONIP '02., Singapore, 2002, pp. 750-754 vol.2.

- [28] Martínez F., Encinas M., Rose C., Orrante J., “Detección de la intención de movimiento a partir de señales electromiográficas utilizando redes neuronales”, *Revista de Ingeniería Eléctrica* 1(2):52-59, 2017.
- [29] García J., Mendoza L., “Adquisición y procesamiento de señales EMG para controlar movimiento de un brazo hidráulico”. *Mundo FESC*, 4(7):49-60, 2014.
- [30] Morbidoni C., Cucchiarelli A., Fioretti S. and Di Nardo F., “A Deep Learning Approach to EMG-Based Classification of Gait Phases during Level Ground Walking”, *Electronics* 8(8): 894, 2019.
- [31] Jianhua Wang, Huichao Ren, Weihai Chen, Peng Zhang, “A Portable Artificial Robotic Hand Controlled by EMG Signal Using ANN Classifier,” *Proceeding of the 2015 IEEE International Conference on Information and Automation Lijiang, China*, pp. 2709-2714, Agosto 2015.
- [32] Luna V. P., *Biomecánica de la Marcha Humana Normal y Patológica*, 2ª ed. Vol1, Valencia, España: Instituto De Biomecánica de Valencia, 1999.
- [33] Pons J., *Wearable Robots: Biomechatronic Exoskeletons*, West Sussex, PO19 95Q, England: John Wiley & Sons, Ltd, 2008.
- [34] Berzal F., *Redes Neuronales & Deep Learning*, Edición independiente, Granada, 2018.
- [35] Géron A., *Hands-On Machine Learning with Scikit-Learn & TensorFlow*, O'Reilly, Sebastopol, CA, USA, 2017.

- [36] Llamas L., "Leer y escribir en una tarjeta SD o microSD con Arduino". Fecha de Consulta: agosto 2019, Disponible en línea: <https://www.luisllamas.es/tarjeta-micro-sd-arduino/>.
- [37] Llamas L., "Conectar Arduino por Bluetooth con los módulos HC-05 ó HC-06". Fecha de Consulta: agosto 2019, Disponible en línea: <https://www.luisllamas.es/?s=Bluetooth+HC-06>.
- [38] Caesarendraa W., Leksona S., Mustaqima K., Winotob A., "A Classification Method of Hand EMG Signals Based on Principal Component Analysis and Artificial Neural Network," Proceeding of the 2016 International Conference on Instrumentation, Control and Automation (ICA), pp. 22-27, Agosto 2016.