

**Centro de Enseñanza Técnica y Superior, CETYS
Universidad**



**Maestría en ingeniería e innovación con orientación en
Sistemas y tecnologías de la información.**

**Categorización optimizada de señales Electromiográficas del
músculo Vasto intermedio relacionado con amputaciones
transfemorales.**

Tesis

Para cubrir parcialmente los requisitos necesarios para obtener el grado de
Maestro en ingeniería

Presenta:

Efraín Atenogenes Mejía González

Ensenada, Baja California, México
2020

Tesis defendida por
Efraín Atenogenes Mejía Gonzales

y aprobada por el siguiente Comité

Dr. Josué Aarón López Leyva
Director de tesis

Miembros del comité

Dr. Gerardo Hirata Salazar
Sinodal

Dr. Carlos Antonio González Campos
Sinodal

Mtra. Amanda Nieto Sánchez
Coordinador del Posgrado

Dra. Dalia Holanda Chávez García
Director de Escuela de Ingeniería

Resumen de la tesis que presenta Efraín Atenogenes Mejía González como requisito parcial para la obtención del grado de Maestro en Ciencias en Maestría en ingeniería e innovación posgrado con orientación en Robótica y automatización.

Resumen aprobado por:

Dr. Josué López Leyva
Director de tesis

En este trabajo se presenta un algoritmo clasificador de señales EMG invasivas para tres condiciones médicas (clases): un sujeto saludable (clase 1), un sujeto con Miopatía (clase 2) y un sujeto con Neuropatía (clase 3). La clasificación de las señales está basada en un vector de características con parámetros temporales, el desempeño del algoritmo clasificador para el gesto 1 fue de 50%, el algoritmo se optimizó basado en una correlación de los parámetros temporales de todas las clases, con esto se determinó aquellos parámetros que no contribuyen al éxito de la clasificación, y solo consumen recursos computacionales, el desempeño del algoritmo clasificador con el vector de características optimizado para la clase 1 fue de 75%, dicha clasificación mejoró y se consiguieron disminuir los recursos computacionales. En la segunda parte de la tesis, se describe el diseño e implementación para la obtención y clasificación de señales EMGs tomadas del músculo Vasto intermedio de los músculos cuádriceps para los gestos: caminar, correr, subir escaleras y bajar escaleras. La clasificación de los gestos obtenidos se llevó a cabo con un vector de características de parámetros temporales, utilizando el aprendizaje automático supervisado para el análisis discriminante lineal, obteniendo un desempeño de la clasificación de acuerdo a la matriz de confusión a los gestos: subir escaleras: 100%, bajar escaleras: 67%, caminar: 100% y correr: 78%.

Palabras clave: Clasificación de señales, EMGs, parámetros temporales

Abstract of the thesis presented by Efraín Atenogenes Mejía González as a partial requirement to obtain the Master of Science degree in Maestría en ingeniería e innovación with orientation in Robotics and Automation

Abstract approved by:

Dr. Josué López Leyva
Thesis Director

In this paper, a classification algorithm of invasive EMG signals is presented for three medical conditions(classes): a healthy subject (class 1), a subject with myopathy (class 2) and a subject with neuropathy (class 3). The classification of the signals is based on a feature vector with temporal parameters, the performance of the classification algorithm for gesture 1 was 50%, the algorithm was optimized based on a correlation of the temporal parameters of all classes, with this determined those parameters that did not contribute to the success of the classification, and only take computational resources, the performance of the classification algorithm with the optimized feature vector for class 1 was 75%, said classification improved and the computational resources were reduced.

In the second part of the paper, the design for obtaining and classifying EMG signals taken from the vastus medialis muscle for gestures is described: walking, running, climbing stairs and down stairs. The classification of the gestures obtained was carried out with a vector of characteristics of temporal parameters, and using a supervised machine learning with discriminant analysis, obtaining a performance of the classification according to the gestures: climbing stairs: 100%, descending stairs: 67%, walk: 100%, run: 78%.

Keywords: Signal classification, EMGs, temporal parameters

Dedicatoria

A mi padre, por todo el apoyo brindado.
Gracias.

“Enseñarás a volar,
pero no volarán tu vuelo.
Enseñarás a soñar,
pero no soñarán tu sueño.
Enseñarás a vivir,
pero no vivirán tu vida.
Sin embargo. . .
En cada vuelo,
En cada vida,
En cada sueño,
Perdurará siempre la huella
del camino enseñado.”
Madre teresa de Calcuta

Agradecimientos

A los investigadores del Centro de Enseñanza Técnica y Superior (CETYS) de Ensenada por brindarme de sus conocimientos en este proceso de formación.

Al Consejo Nacional de Ciencia y Tecnología (CONACyT) por brindarme el apoyo económico para realizar mis estudios de maestría por medio de la beca nacional con número de CVU 769348.

A mi director de tesis el Dr. Josué López Leyva, por compartir sus conocimientos y guiarme en este trabajo.

Tabla de contenido

Resumen	ii
Abstract.....	iii
Dedicatoria.....	iv
Agradecimientos	v
Lista de figuras	x
Lista de tablas	xii
Capítulo 1. Introducción	1
1.1 Antecedentes.....	1
1.2 Justificación.....	5
1.3 Hipótesis.....	6
1.4 Objetivos.....	6
1.4.1 Objetivo general	6
1.4.2 Objetivos específicos	6
Capítulo 2. Marco teórico	7
2.1 Movimiento muscular	7
2.2 Electromiografía.....	7
2.3 Electromiografía invasiva.....	8
2.4 Electromiografía de superficie	8
2.5 Electrodo.....	9
2.6 Miopatía y Neuropatía.....	10
2.7 Electromiógrafo.....	11
2.8 Segmentación	11
2.9 Extracción de características.....	12

	vii
2.10 Características en el dominio del tiempo	12
2.11 Características dominio de la frecuencia	13
2.12 Redes neuronales	13
2.13 Aprendizaje de clasificación Matlab	14
2.14 Discriminante lineal	14
Capítulo 3. Metodología	16
Parte 1 Algoritmo optimizado para el reconocimiento de enfermedades musculares basado en el análisis de parámetros temporales y coeficientes de correlación	16
Parte 2 Reconocimiento automático para gestos de pierna basado en lector de Electromiografía Portable	21
Capítulo 4. Resultados y Discusión	26
Parte 1	26
Parte 2	33
Capítulo 5. Conclusiones	36
Parte 1	36
Parte 2	36
Bibliografía	38
Anexo 1 Códigos desarrollados	41
Parte 1. Código utilizado para la clasificación de las condiciones médicas	41
Parte 2 Algoritmo utilizado para la extracción de características de la EMGs del Vasto intermedio	45
Anexo 2 Problemática	47
2.1. Claridad del problema que resuelve	47

2.2 Empresas potenciales en la localidad que podrían beneficiarse con la implementación del algoritmo:	47
Anexo 3. Paquete tecnológico transferible.....	48
3.1 manual de conexiones para la obtención de EMGs	48
3.2 Código Arduino para la obtención de la EMGs	49
3.3 Guía para la colocación de electrodos en el músculo Vasto intermedio, para la lectura de la flexo- extensión de la rodilla.	49
Anexo 4. Análisis de Pertinencia del proyecto.....	50
Anexo 5. Análisis de Viabilidad de éxito	50
5.1 Análisis FODA	50
5.2 Análisis Canvas	52
5.2.1 Propuesta de valor.....	52
5.2.2 Relaciones con los clientes.....	52
5.2.3 Segmentos de mercado	52
5.2.4 Actividades claves.....	52
5.2.5 Recursos claves.....	52
5.2.6 Socios claves.....	53
5.2.7 Estructura de costos	53
Anexo 6. Impactos potenciales y esperados para el beneficiario.	53
Anexo 7 Administraciones del proyecto.....	53
7.1 Administración del alcance (Recolección de requisitos, Definición del alcance y Creación de la EDT).	54
7.2 Administración del costo (Presupuesto y Flujo de efectivo)	56

7.3 Administración de la calidad (Plan de Calidad)	57
7.4 Administración de los recursos humanos (Plan de Recursos Humanos).....	58
7.5 Administración de las comunicaciones (Plan de Comunicaciones).....	59
7.6 Administración de los riesgos (Plan de Respuesta a los riesgos)	59
7.7 Administración de las adquisiciones (Plan de Adquisiciones)	60
7.8 Administración de la integración	61
7.8 Evidencia de ejecución y control de proyecto.	63
7.9 Evidencia de cierre de proyecto	64

Lista de figuras

Figura 1 Ensamble de Señal EMG de una persona saludable, 20 sub-señales con 2000 muestras cada una. Recuperado de (Mejía-González, 2019)	17
Figura 2 Ensamble de Señal EMG de un individuo con Miopatía., 20 sub-señales con 2000 muestras cada una. Recuperado de (Mejía -González, 2019)	17
Figura 3 Ensamble de Señal EMG de un individuo con Neuropatía. 20 sub-señales con 2000 muestras cada una. Recuperado de (Mejía -González, 2019)	18
Figura 4 Señal EMG representativa para cada condición médica. (Rojo: saludable. negro: Miopatía. Azul: Neuropatía). Recuperado de (Mejía -González, 2019).	18
Figura 5 Vector de características de la señal EMG de una persona saludable. Recuperado de (Mejía -González, 2019)	19
Figura 6 Vector de características de la señal EMG de Miopatía Recuperado de (Mejía- González, 2019) 20	
Figura 7 Vector de características de la señal EMG Neuropatía Recuperado de (Mejía -González, 2019). 20	
Figura 8 Arreglo del Hardware utilizado en la adquisición de datos.	21
Figura 9 Señal representativa, para el gesto bajar escaleras, pierna derecha (Amplitud contra muestras)	22
Figura 10 Ensamble de las señales EMG para el gesto Bajar escaleras. (Amplitud contra muestras) Clase #1. Muestras contra amplitud.....	23
Figura 11 Ensamble de la señal EMG para subir escaleras clase #2. Muestras contra amplitud	23
Figura 12 Ensamble de la señal EMG para caminar clase #3. Muestras contra amplitud	24
Figura 13 Ensamble de la señal EMG para correr clase #4. Muestras contra amplitud	24
Figura 14 Desempeño del algoritmo para la clase uno, con una tolerancia de $\pm 20\%$	26
Figura 15 Gráfica de caja que muestra el desempeño del algoritmo para la clase 2, con una tolerancia de $\pm 20\%$	27
Figura 16 Gráfica de caja que muestra el desempeño del algoritmo para la clase 3, con una tolerancia de $\pm 20\%$	27
Figura 17 Diagrama de caja del rendimiento del algoritmo para la clase 1, considerando una tolerancia de $\pm 10\%$	28
Figura 18 Diagrama de caja del rendimiento del algoritmo para la clase 2, considerando una tolerancia de $\pm 10\%$	28
Figura 19 Diagrama de caja del rendimiento del algoritmo para la clase 3, considerando una tolerancia de $\pm 10\%$	29

Figura 20 Diagrama de caja del rendimiento del algoritmo para la clase 1, considerando una tolerancia de $\pm 5\%$	29
Figura 21 Diagrama de caja del rendimiento del algoritmo para la clase 2, considerando una tolerancia de $\pm 5\%$	30
Figura 22 Diagrama de caja del rendimiento del algoritmo para la clase 3, considerando una tolerancia de $\pm 5\%$	30
Figura 23 muestra la correlación de coeficientes para la clase 1.	31
Figura 24. Correlación de coeficientes para la clase 2	31
Figura 25 Correlación de coeficientes para la clase 3	32
Figura 26 Correlación de coeficientes para todas las clases	32
Figura 27 Desempeño del algoritmo, con el vector de características optimizado para la clase 1	33
Figura 28 Tiempo requerido por el algoritmo para su entrenamiento y clasificación de las condiciones fisiológicas.	33
Figura 29 Matriz de confusión para todas las clases.	34
Figura 30 Curva ROC para las clases 2 y 4.	35
Figura 31 Conexión entre el Dispositivo Myo Ware y Arduino Uno	48
Figura 32 Conexión Arduino - Myoware	48
Figura 33 Posición Myo ware para el registro de EMGs en el muslo Vasto intermedio.	49
Figura 34 Análisis Foda.....	51
Figura 35. Formato de avance de proyecto.....	54
Figura 36 Documentación de requisitos	54
Figura 37 EDT.....	55
Figura 38 Administración recursos humanos	58
Figura 39 Administración de la integración.....	62
Figura 40 evidencia cierre de proyecto.....	64

Lista de tablas

Tabla 1 Recomendaciones para ubicaciones de sensores en los músculos de la cadera o la parte superior de la pierna (Tomado y traducido de: http://www.seniam.org/)	10
Tabla 2 Administración del costo.....	56
Tabla 3 Administración de la calidad	57
Tabla 4 Administración de las comunicaciones.....	59
Tabla 5 Tabla de riesgos	60
Tabla 6 Administración de las adquisiciones.....	61
Tabla 7 Administración de los costos.....	63

Capítulo 1. Introducción

1.1 Antecedentes

En los últimos años hemos podido constatar el crecimiento exponencial de la tecnología, los teléfonos celulares con sus pasos agigantados, nos sorprendíamos simplemente con poder comunicarnos con una simple llamada, un mensaje de texto, nunca imaginamos estar presenciando avances tan grandes, las redes sociales y todo lo que englobamos en los sistemas inteligentes y el internet de las cosas (IoT), paralelo a esto cada día tenemos novedades en ámbitos tan variados, como lo son telecomunicaciones, transporte, la inteligencia artificial, la robótica, etc. Un aspecto importante en el desarrollo de las prótesis es la miniaturización de los procesadores quienes juegan un papel crucial ya que son el cerebro de las prótesis eléctricas, y día a día vemos procesadores más pequeños con mayores capacidades de cómputo, y nos hace pensar en sistemas de tomas de decisión más complejos que se verán reflejados en una mejor respuesta por el sistema. Cabe señalar que la Real Academia Española define prótesis como: “Procedimiento mediante el cual se repara artificialmente la falta de un órgano o parte de él; o aparato o dispositivo destinado a esta reparación” y como “pieza, aparato o sustancia que se coloca en el cuerpo para mejorar alguna de sus funciones, o con fines estéticos” (RAE, 2019). Hasta la fecha la prótesis más antigua de la que se tiene registro, es la conocida como “El dedo gordo del Cairo” data aproximadamente de las fechas 1029-607 A.C, la cual se exhibe en el museo del Cairo en Egipto. (BBC, 2007). Este tipo de prótesis con la finalidad estética más allá que para una tarea específica (funcional) son las más antiguas de las que se tiene registro. En base a su funcionalidad podemos distinguir la siguiente clasificación: Prótesis de restauración cosmética, prótesis accionada por el cuerpo, prótesis accionada por energía externa, prótesis híbridas y prótesis de propósito específico. (Moreira, 2003). Dentro de las prótesis de restauración cosmética, aunque no son destinadas a suplir una función en específico, son las más populares y muchas veces las opciones más económicas. Las prótesis accionadas por el cuerpo tienen funciones limitadas y generalmente están enfocadas en una actividad en concreto, tal es el caso de pinzas o ganchos en los extremos. Las prótesis activas dentro de las cuales destacan: de botones pulsadores, arnés, eléctricas, hidráulicas y Mioeléctricas. Por último, tenemos a las prótesis híbridas, que pueden presentar combinaciones de prótesis activas y accionadas por el cuerpo, donde la fuerza adicional es obtenida de un agente externo.

En el caso de las prótesis activadas por los músculos (Mioeléctricas), el primer registro se da gracias a Ferdinand Sauerbruch, quien logró conectar la musculatura flexora a un mecanismo artificial a través de

unas varillas de marfil introducidas subcutáneamente haciendo posible el movimiento mecánico de la prótesis como respuesta a la contracción muscular (Romero, 2011). A finales de 1946 se empiezan a tener avances en las prótesis accionadas por el cuerpo para dar lugar a sistemas de propulsión asistida, dando origen a prótesis neumáticas y eléctricas (González, 2005). Un sistema de propulsión asistida se apoya de algún elemento externo al cuerpo humano para generar el movimiento. Las prótesis eléctricas hacen uso de motores eléctricos conectados a baterías y su control puede variar, siendo dispositivos de encendido/apagado o pre-programados para funcionar de manera específica. En este contexto tenemos a las prótesis Mioeléctricas, las cuales son prótesis eléctricas en el cual el control de los motores eléctricos está dado por la interpretación de la lectura de las señales mioeléctricas producidas por unidades motoras de los músculos. Se caracterizan por su gran velocidad y precisión. Las prótesis mioeléctricas surgen en Rusia alrededor de 1960, y consisten en obtener las señales eléctricas producidas cuando el músculo se contrae o extiende. El control mioeléctrico es el esquema más popular de control, se basa en la interpretación de las señales electromiográficas del cuerpo, esto es debido a que los músculos son el tejido que genera el movimiento en los seres humanos, generan movimiento al contraerse o extenderse. Cuando se desea realizar algún movimiento, los impulsos nerviosos van del cerebro al tejido muscular, en el tejido muscular los impulsos nerviosos liberan un compuesto químico, el cual es el responsable de la contracción muscular, lo cual produce movimiento (Butler, 2002).

Con los avances en la ingeniería, medicina y diversas áreas de la ciencia, se han establecido claramente las rutas de los procesos involucrados en el movimiento muscular, la electromiografía permite registrar los potenciales eléctricos desarrollados en los músculos estriados (Galindo, 2011). A mediados del año 1786 Luigi Galvani experimento con ranas, con una máquina electrostática, y pudo demostrar la relación entre la electricidad y la musculatura de los organismos vivos (Álvarez Fiallo, 2006). Por su parte Guillaume Benjamín *Amand Duchenne*, quien es conocido como el padre de la Electrofisiología, descubrió que una estimulación eléctrica puede provocar movimientos musculares y fue el primero en utilizarlos en una terapia, sentando con ello las bases de la electromiografía. Sus resultados están plasmados en su obra *De l'électrisation localisée et de son application à la pathologie et à la thérapeutique (1855)* (Fernández Vázquez, 2006). Con la recopilación de la información, *Erlanger J* y *Spencer Gasser H* lograron los primeros trabajos sobre amplificación de señales y con el apoyo de un osciloscopio de rayos catódico lograron estimular una fibra nerviosa trabajo que les sirvió para obtener el premio nobel en el año 1944. (Fernández, 2007).

La electromiografía (EMG) registra la diferencia de potencial generado en la membrana externa de la fibra muscular (Fernández, 2007). Existen dos formas de medir la diferencia de potencial, en ambos casos se

utilizan electrodos, ya sean superficiales (electromiografía de superficie EMGs) o intramusculares (EMG invasiva), la identificación de la técnica a usar depende del propósito que se espera asignarle a la lectura, para el caso de la EMG invasiva sus usos generalmente están destinados a factores patológicos o médicos de las unidades motrices, el uso de EMG invasiva para la detección de Neuropatía y Miopatía está establecido desde hace años, en este contexto tenemos a Sara vitoria (Rubio, 2014) quien menciona que la presencia de actividad espontánea en forma de fibrilación en la electromiografía con aguja coaxial es un método con alto rendimiento para el diagnóstico precoz de Miopatía.

Acerca de la Neuropatía Almendras reporta (Almendras, 2019) que la electromiografía con electrodo de aguja es una herramienta útil, ya que la presencia de signos de reinervación en los músculos del territorio ciático constituyen un factor de buen pronóstico. Por su parte la EMGs está destinada al estudio o comprensión del comportamiento muscular global, debido a que se obtiene la suma de potenciales de las unidades motoras (Pinzón, 2012). Larraz (Larraz, 2009) en el trabajo: Diseño de un sistema de reconocimiento del habla mediante electromiografía expone una eficiencia del 71% de efectividad en la clasificación de patrones del habla utilizando EMGs, dejando claro que el uso de las señales EMGs caracteriza cada gesto de manera específica. Giordano et al. (2018) utilizando entrenamiento supervisado y lecturas de EMGs consiguió clasificaciones superiores a 80% para gestos del antebrazo. En el trabajo “Procesamiento de señales Emg en un sistema embebido para el control neuronal de un brazo robótico” Alejandro Maldonado deja claro que no es necesario aplicar técnicas que incluyan parámetros frecuenciales para el procesamiento y clasificación de señales EMGs, y que estos parámetros desperdician recursos computacionales útiles (Maldonado, Guerrero, & Ortiz, 2018). Por otro lado, Chung Liu et al (2018) declara que “El modelo propuesto puede reconocer los mismos 5 gestos que el sistema de reconocimiento propietario del Myo Armband, logrando una exactitud de reconocimiento promedio de $85\% \pm 15.21\%$ ”.

La construcción general de una prótesis basada en electromiografía consta de la obtención de señales electromiográficas, amplificación, procesamiento, cómputo, y envío del control a motores o servomotores, encargados del movimiento mecánico. (Andrade, 2011). Gran parte del éxito de las prótesis mioeléctricas está basado en el correcto procesamiento de las señales obtenidas por la electromiografía, estas señales proveen de información tanto en el dominio del tiempo como en el dominio de la frecuencia. La correcta clasificación de estas señales hace posible la replicación de la clasificación de las señales en diferentes individuos, ya que los músculos involucrados en los movimientos son siempre los mismos y las señales varían de individuo a individuo, solo en magnitud ya que la señal es afectada por la condición física de cada individuo. (Pinzon, 2009). Sin embargo, fue a mediados de los años de 1900, cuando empiezan a

introducirse electrodos para registro de electromiografías gracias a Edgar Douglas Adrián y Alan Lloyd Hodgkin (Gila, 2009).

La clasificación de señales en términos generales implica, contar con una base de datos de características (vector de características) para cada gesto (movimiento específico) asociado a una señal electromiográfica. El primer paso para asociar una señal EMGs a un gesto está dado por la aplicación de técnicas de extracción de características (Harold A. Romo, 2007), en la cual identificamos dos grandes grupos, las que se componen de parámetros en el dominio del tiempo (temporales) y las que se encuentran en el dominio espectral (frecuenciales). Los parámetros temporales no requieren ni un tipo de transformación de la señal, son ampliamente utilizadas por su rápido procesamiento, sencillez y velocidad de obtención, para las señales frecuenciales algunos de los tratamientos aplicados incluyen transformadas rápidas de Fourier (FFT), la transformada de tiempo corto de Fourier, análisis espectral utilizando transformada wavelet (continuous Wavelet Transform CWT), Wavelet Packet Transform WPT, cabe señalar que el análisis de las señales en el dominio espectral implica una mayor capacidad de cómputo y un mayor tiempo de procesado, pero por su parte proporciona mejores características asociadas a un gesto.

Las características estadísticas más utilizadas en los parámetros temporales incluyen: valor absoluto, longitud de onda, cambios en la pendiente de la señal, amplitud de willison, curtosis, oblicuidad, cuartiles, percentiles, rango, entre otras técnicas estadísticas. Entre las herramientas utilizadas en estadística, aprendizaje automático y machine Learning, tenemos el uso la técnica Análisis discriminante Lineal (LDA), que es capaz de encontrar una combinación lineal entre las características de dos o más objetos diferentes. (Guevara, 2019). Aerrano et al (2018) llega a la conclusión “El algoritmo PCA es muy parecido a LDA con la sutil diferencia que LDA hace una mejor reducción de la dimensionalidad de los datos y además una mejor separación de clases debido a que LDA coloca una etiqueta a los datos”.

En 1943, Warren McCulloch y Walter Pitts son los primeros en presentar un modelo de neuronas artificiales, quienes también son conocidos como los pioneros de la inteligencia artificial. (Pospíchal, 2015). (Cabezas, 2018) Reporta un éxito de clasificación para señales de Electroencefalografía (EEG) del 86% utilizando la técnica de Análisis de discriminante lineal (LDA) sobre las técnicas de Análisis discriminante cuadrática (QDA) y el coeficiente de correlación de Pearson. Por otra parte (Carino-Escobar, 2016) reporta un éxito de clasificación del 80% para tres clases de EEG utilizando las técnicas LDA y redes neuronales artificiales del tipo mapas auto-organizados (SOMs). Las redes neuronales juegan un papel muy importante no solo en la clasificación de señales, si no en temas como optimización, identificar patrones, predicción traducción, análisis, entre otros. Las redes neuronales son un modelo computacional capaz de realizar cálculos complejos, está constituida de neuronas, que son la unidad básica de una red y estas se agrupan

para formar una red neuronal. Esta neurona cuenta con valores de entrada y valores de salida, que pueden interconectarse entre neuronas.

1.2 Justificación

Transportarse en la actualidad es algo que hacemos todos los días y se puede hacer de diferentes formas; ya sea en automóvil, avión, barco, bicicleta y desde luego, podemos transportarnos con nuestras propias piernas. (Ruiz, 2014). A nivel mundial las lesiones medulares son frecuentes en personas activas por causas como accidentes de tránsito (46%), caídas (18%), actos violentos (17%), deporte (13%) entre otros (6%). De estos casos aproximadamente el 44% resulta en paraplejia, cuyo mayor impedimento es la pérdida del movimiento de los miembros inferiores. Por otra parte, una patología es un trastorno anatómico y fisiológico de órganos, tejidos y fluidos corporales, que padece una persona. Existen patologías que generan cambios al interior de la rodilla que producen malestar al paciente, provocando inestabilidad emocional, física y económica. Algunas patologías se producen en la articulación de la rodilla, específicamente en los tendones y los músculos que son los encargados del movimiento. Las enfermedades más conocidas son la artritis, desgaste natural y lesiones en ligamentos o tendones La rehabilitación es primordial para evitar trastornos adicionales provocados por el mismo paciente. Por ello, es común utilizar dispositivos robóticos que proporcionan facilidad en la rehabilitación. Entre estos se encuentran los exoesqueletos que son dispositivos capaces de generar un incremento de fuerza, velocidad y rendimiento al paciente en actividades cotidianas que involucran el movimiento de articulaciones de la rodilla (Andrés, 2016). Uno de los métodos más comunes de movilidad para las personas parapléjicas es la silla de ruedas, pero presentan dificultades cuando se desplazan por superficies irregulares o escaleras. Incluso con los avances de las sillas de ruedas eléctricas, la movilidad sigue estando limitada a terreno liso, excluyendo las zonas al aire libre lo que afecta considerablemente la parte psicológica y social del usuario. Sumado a lo anterior, la calidad de vida de una persona parapléjica está destinada a una dependencia continua de las demás personas para una ayuda en el desplazamiento. El deseo de tener mayor movilidad e independencia que la brindada por la silla de ruedas ha encontrado una realización a través del desarrollo de exoesqueletos robóticos, los cuales son, básicamente, un dispositivo que es usado sobre el cuerpo humano a manera de prenda de vestir, que son mecánicamente compatibles con la anatomía humana, para permitir el movimiento seguro en el usuario y no obstruir u oponer resistencia al mismo. Estos dispositivos se usan alrededor de las piernas y espalda, el movimiento se obtiene gracias a motores eléctricos que mueven las piernas para brindar locomoción mientras que el balance se obtiene con muletas. Los exoesqueletos no sólo proporcionan la habilidad de locomoción a las personas con

discapacidades sino también la oportunidad de sentirse sanas. Actualmente hay algunos exoesqueletos que están en desarrollo y que han empezado con la transformación, como lo son el eLegs de Berkeley Bionics, Mina del Institute for Human and Machine Cognition, ReWalk de Argo Medical Technologies, y el exoesqueleto Vanderbilt de la Universidad de Vanderbilt. El inconveniente de estos dispositivos es su precio, que oscila entre U\$60.000 y U\$140.000 (Venegas, 2016) Los beneficios de los sistemas robóticos no se limitan solamente a la imitación del hombre en sus tareas diarias. Es por esta razón que una correcta clasificación de señales EMGs basada en parámetros temporales contribuye significativamente en el desarrollo de prótesis de bajo costo reduciendo costos y tiempo de procesado.

1.3 Hipótesis.

Reducir la cantidad parámetros estadísticos de un vector de características de las señales Electromiográficas obtenidas del músculo vasto intermedio para las acciones caminar, correr, subir escaleras y bajar escaleras, basado en parámetros temporales contribuye a una optimización en la clasificación

1.4 Objetivos

1.4.1 Objetivo general

Obtener, clasificar y optimizar el vector de características de las señales EMG del músculo Vasto intermedio.

1.4.2 Objetivos específicos

- 1) Determinación y análisis de parámetros temporales que describen una señal electromiográfica.
- 2) Obtener señales EMG reales y señales de una base de datos.
- 3) Clasificación de la señal EMG obtenida de la base de datos.
- 4) Clasificación de las señales EMG obtenidas en la práctica.
- 5) Analizar aspectos técnicos de clasificadores de señales EMG
- 6) Optimización de los parámetros temporales y clasificadores.

Capítulo 2. Marco teórico

2.1 Movimiento muscular

El sistema neuro muscular encargado del movimiento y rigidez del cuerpo, está constituido por los sistemas músculo-Esquelético y el sistema nervioso, trabajan en armonía para producir movimiento con la recepción de un estímulo. El sistema nervioso tiene como componentes principales las neuronas, estas se encuentran conectadas entre sí y tienen la propiedad de transmitir estímulos dentro de los tejidos nerviosos, usando señales electroquímicas. (Márquez, 2008). Por otro lado, el sistema muscular está constituido por más de 600 músculos y es el encargado de generar movimiento en el cuerpo humano y proporcionar estabilidad a través de la contracción o relajación de las fibras musculares. El músculo está compuesto de células con la capacidad de contraerse o relajarse. Existen tres tipos de tejido muscular: músculo esquelético, músculo liso y músculo cardiaco. Con respecto al músculo esquelético, identificamos 2 tipos de músculos, los músculos voluntarios y los involuntarios. Por su parte los músculos involuntarios son controlados por el sistema nervioso, el individuo no tiene control sobre de ellos como lo son los músculos del aparato respiratorio, del aparato circulatorio o las vísceras. Los músculos de control voluntario o músculos estriados, son los que el individuo puede controlar como bíceps, cuádriceps o tríceps. Los músculos esqueléticos voluntarios constituyen la parte activa del aparato locomotor, se insertan en los huesos mediante tendones o aponeurosis, su capacidad de contracción y relajación permiten generar movimiento. Cuando el músculo se contrae, transmite la tensión a los huesos en los que se inserta y se produce el movimiento (Mora, 2000). El conjunto que forma una motoneurona alfa y las fibras musculares (FMs) inervadas por ella se conoce como unidad motora (UM) y constituye la unidad anatómica y funcional del músculo. El número de fibras musculares varía de un músculo a otro. Dentro de las unidades motoras simples existe el intercambio de neurotransmisores acetilcolina (ACh). Cuando existe un potencial de acción neuronal, los canales de iones se dilatan, permitiendo que exista un intercambio de iones Na^+ y Cl^- , este gradiente iónico provoca una despolarización de membrana, desencadenando una relajación muscular. (Osorio, 2007). En una contracción voluntaria la fuerza es controlada por un cambio en la frecuencia de las actividades de la UM, esto está directamente relacionado y existe una velocidad dependiente de la fuerza aplicada.

2.2 Electromiografía

El registro de potenciales generados por la actividad eléctrica de los músculos a través de electrodos, se conoce como Electromiografía. La señal registrada se conoce como señal de electromiografía, está

compuesta por la suma de un tren de acción potencial de la unidad motora (Motor Unit Action Potential (MUAP)) generados por la activación de unidades motoras (RYMER, 2004). El uso principal de la electromiografía es con fines médicos. Entre su uso está la identificación de enfermedades neuromusculares, la esencia de esto consiste en que las alteraciones en la morfología de los potenciales de las unidades motoras, puede expresarse en términos de cambios anatómicos y fisiopatológicos. Existen 2 formas de electromiografía, su diferencia radica en los electrodos utilizados y el propósito del estudio. (Cifuentes & Macmahon, 2014). La principal diferencia entre estas técnicas, EMG superficial y EMG invasiva, radica en la precisión de los potenciales eléctricos que pueden ser registrados y en el tipo de electrodos que utilizan.

2.3 Electromiografía invasiva

La electromiografía invasiva se aplica al estudio de enfermedades Neuromusculares desde hace casi 60 años, con especial enfoque al estudio de Miopatías y análisis clínicos, por su capacidad de registrar el potencial eléctrico directamente de las unidades motoras. En la Electromiografía invasiva, los electrodos son insertados de manera intramuscular (agujas), generalmente bajo supervisión médica, esta invasión permite registrar el potencial eléctrico a nivel de una moto-neurona, la cual puede definirse como la neurona motora alfa que inerva a las fibras musculares. Las fibras musculares de una sola unidad motora están ampliamente dispersas en todo el músculo, en donde se requiere un control preciso. Entre los primeros estudios de electromiografía para identificar enfermedades neuromusculares encontramos a Benny- Brown, quien, a principios del año 1938, identificó 2 problemas eléctricos producidos por una motoneurona, que terminan en fibrilaciones y pérdida del número de unidades motoras.

2.4 Electromiografía de superficie

La EMG de superficie (EMGs) utiliza electrodos que son colocados en la superficie de la piel. Las señales registradas son muy pequeñas pudiendo encontrarse en el orden de 50 μV hasta los 5 mV, y en una frecuencia que puede variar de los 5 a los 10,000 Hz. Estas señales EMGs producidas por el cuerpo requieren amplificación y es llevada a cabo por los amplificadores operacionales inmersos en el dispositivo que registran la actividad conocidos como Electromiógrafos. Los electrodos de superficie son transductores que convierten el flujo iónico en corriente eléctrica, los electrodos deben adherirse a la piel del sujeto de estudio, la señal proveniente de los electrodos, es procesada por el Electromiógrafo, el cual, en sus diferentes versiones se encarga de amplificar, filtrar y digitalizar la señal fisiológica. (Vadursi, 2010).

2.5 Electrodo

Uno de los aspectos menos estandarizados de la EMGs, es la homologación de la colocación de los electrodo, cuando se desea estudiar un músculo en particular. Esto ha desencadenado en que existan diferentes registros de señales para un mismo músculo. Teniendo en cuenta esto, en 1996 surge Surface Electromyography for Non invasive Assessment of Muscles (SENIAM), como un protocolo para colocar electrodo superficiales. En este protocolo SENIAM propone seis pasos para una medición de EMGs: Selección de electrodo, Preparación de la piel, Postura del paciente, localización de los electrodo, fijación de electrodo y Prueba de conexiones. La tabla 1. Muestra la recomendación dada por SENIAM para la adquisición de la señal en el músculo Cuádriceps femoral, en su división Vasto intermedio.

Tabla 1 Recomendaciones para ubicaciones de sensores en los músculos de la cadera o la parte superior de la pierna (Tomado y traducido de: <http://www.seniam.org/>)

	Músculo
Nombre	Cuádriceps femoral
Subdivisión	Vasto medial
	Anatomía muscular
Origen	Parte proximal de la línea intertrocantérea, bordes anterior e inferior del trocánter mayor, labio lateral de la tuberosidad glútea, mitad proximal del labio lateral de la línea áspera y tabique intermuscular lateral
Inserción	Borde proximal de la rótula y a través del ligamento rotuliano
Función	Extensión de la articulación de la rodilla.
	Recomendación para la colocación de electrodos.
Postura de inicio.	Sentado en una mesa con las rodillas ligeramente flexionadas y la parte superior del cuerpo ligeramente doblada hacia atrás
Tamaño de electrodos.	Tamaño máximo en la dirección de las fibras musculares: 10 mm.
Distancia entre electrodos	20 mm
	Colocación de los electrodos
locación	Los electrodos deben colocarse a 2/3 en la línea desde la espina iliaca anterior superior al lado lateral de la rótula
orientación	En dirección a las fibras musculares
Fijación en la piel	Cinta doble cara, anillos o banda elástica

2.6 Miopatía y Neuropatía

La neuropatía afecta al nervio periférico, en alguno de sus componentes como lo son la mielina o el axón. Existen numerosas causas por las cuales se pueden producir alguna neuropatía, algunas consecuencias suelen ser metabólicas, infecciosas, autoinmunidad, disproteinemias, para-neoplásicas o tóxicas. La sintomatología generalmente abarca debilidad muscular, trastornos sensitivos dados por parestesias. El diagnóstico es llevado a cabo después de un minucioso historial clínico, que recaban datos sobre edad de aparición de los síntomas, distribución y asociación con otros síntomas. La neuropatía se confirma con dos estudios funcionales la neuroconducción y la electromiografía, con esto también se define si la neuropatía es axonal o desmielinizante, agudo o crónico (Gómez, 2000). Por otra parte, si el compromiso de la fibra

muscular implica debilidad muscular más proximal asociada a mialgias estamos hablando de una Miopatía, el diagnóstico diferencial de una miopatía depende de la edad de aparición, genética y la distribución de la debilidad muscular. En 1949 Kugelberg estudiaba el control de movimiento muscular y registró potenciales anómalos en miopatías. En forma general se pueden clasificar cuatro tipos de miopatías: Miopatías congénitas, Miopatías de membrana, miopatías inflamatorias y miopatías metabólicas (Gómez, 2000).

2.7 Electromiógrafo

Un Electromiógrafo es un amplificador de alta ganancia (amplifica entre 200 y 5000 veces la señal del músculo) y permite hacer una selección de la frecuencia, entre los rangos de 1 a 2 kHz. Por esta razón a la señal electromiográfica también se le conoce como la suma temporal de las señales eléctricas de fibras musculares a diferentes frecuencias. El estudio de las señales electromiográficas, consiste en el reconocimiento de características de la señal. Con el desarrollo de la tecnología y de los sistemas de cómputo estas características se pueden analizar de manera más eficiente a través de algoritmos especializados, y reciben el nombre de técnicas de procesamiento digital de señales. Los sistemas clasificadores de señales obtienen las características dividiendo la señal en dominios temporales y frecuenciales. En la adquisición de señales electromiográficas es posible identificar etapas esenciales del proceso: amplificación, filtrado, y la conversión analógico-digital (ADC). La etapa de amplificación toma la señal proveniente de los electrodos en contacto con el sujeto de estudio, esta señal es llevada del registro que puede estar entre los μV y los mV a voltajes más altos para su mejor estudio. La señal amplificada es una mezcla de la señal biológica y ruido ambiental. La depuración y filtrado de la información se lleva a cabo en la etapa de filtrado, la implementación incluye un filtro que pasa bajas frecuencias y uno que deja pasar altas frecuencias (20-1 kHz). La conversión analógica-digital permite transformar señales continuas en señales con valores binarios. El proceso de digitalización contempla las fases de: muestreo, retención, cuantificación y codificación. Con la señal digitalizada y procediendo al procesamiento de señales, la señal es sometida a una extracción de características. (Correa Figueroa, 2016).

2.8 Segmentación

Un segmento es un subconjunto de muestras de una señal electromiográfica. La segmentación se lleva a cabo debido a las limitaciones del análisis en dominio del tiempo, el tiempo de procesamiento no debe ser mayor 300 ms, debido a que los procesadores de cómputo de tiempo real no exceden los 500 ms, el tamaño del segmento generalmente varía de 32 a 250 ms. Existen dos técnicas para la segmentación o

ventaneado de la señal EMG, la segmentación disjunta y la superpuesta (Rechy-Ramírez, 2011). La segmentación disjunta: utiliza segmentos adyacentes de un tamaño predeterminado. Por su parte en la segmentación superpuesta el segmento adyacente siguiente de la señal, contempla una fracción de tiempo de la señal anterior. Cabe señalar que con la señal segmentación superpuesta se incrementa el tiempo de procesado (Romo Romero, 2007).

2.9 Extracción de características

La extracción de características es el proceso mediante el cual se obtiene información relevante de un segmento de la señal EMG, para la creación de un vector de características (VC). Existen tres tipos esenciales de características consideradas en el proceso de creación del VC: características en el dominio del tiempo, en el dominio de la frecuencia y en el dominio tiempo-frecuencia. (Cifuentes & Macmahon, 2014).

2.10 Características en el dominio del tiempo

Las Características temporales están constituida por los parámetros estadísticos de la señal, y no se necesita transformación alguna de los datos, se basa en la amplitud, forma de la onda, frecuencia y aquellas características en el dominio del tiempo. Los parámetros estadísticos más utilizados comprenden: Valor absoluto medio, Mediana, moda, valor medio absoluto, cruces por cero, amplitud willison, cuartiles, percentiles, oblicuidad y curtosis. Estos parámetros son de los más populares cuando hablamos de reconocimiento de patrones de señales EMG. De acuerdo al músculo estudiado los parámetros deben ser examinados y deberá identificarse quienes tienen mayor contribución al vector de características. Los parámetros más utilizados se muestran en las ecuaciones 1, 2,3 y 4 referente a parámetros temporales

El valor absoluto:

$$VAM: \frac{1}{N} \sum_{I=1}^N |X_I| \quad (1)$$

Valor cuadrático medio: Está relacionado directamente con la fuerza de contracción del músculo. (Weiss, Weiss, & Silver, 2015).

$$VCM: \sqrt{\frac{1}{N} \sum_{I=1}^N X^2} \quad (2)$$

Longitud de onda: mejora la integración de las características de la señal EMG. Está definida (P. A. Karthick, 2015).

$$\text{Longitud de onda} = \sum_{l=1}^{N-1} |X_{l+1} - x_l| \quad (3)$$

Desviación estándar:

$$\text{Desviacion estandar} = \sqrt{\frac{1}{N} \sum_{l=1}^N (x_l - \bar{x})^2} \quad (4)$$

2.11 Características dominio de la frecuencia

Para evaluar los componentes de la frecuencia se realiza un gráfico de potencia contra frecuencia denominado análisis espectral. (Caballero, 2002). Las características en el dominio de la frecuencia como: transformada de Fourier, Transformada de Fourier de tiempo corto (ecuación 5), Frecuencia mediana (ecuación 6), la transformada wavelet continua. (Romo, 2007), cotidianamente son los más utilizados para evaluar una señal EMG. Las más utilizadas en la fatiga muscular y en la estimación de fuerza muscular son: Transformada de Fourier de tiempo corto (STFT):

$$STFT(t, w) = \int W * (t-t)x(t) e^{-jw t} dt \quad (5)$$

$W(t)$ es una función de ventana y $*$ representa el complejo conjugado t representa el tiempo y w la frecuencia.

Frecuencia mediana:

$$\text{Frecuencia mediana: } \frac{1}{2} \sum_{i=1}^M PSD_i \quad (6)$$

Donde M es la longitud del PSD (espectro de densidad de potencia).

2.12 Redes neuronales

Las redes neuronales se basan en el funcionamiento del cerebro humano, en particular en el sistema nervioso, el cual se forma de redes de neuronas que poseen bajas capacidades de procesamiento y toda su capacidad se centra en su interconectividad. Una red neuronal es un sistema de computación con la capacidad de procesar información por medio de su estado dinámico, como respuesta a entradas externas. Tiene la capacidad de resolver problemas para tareas como clasificación, identificación, diagnóstico, optimización o predicción. Generalmente existe un tiempo de aprendizaje de la máquina (Matich, 2001). La propiedad más importante de las redes neuronales artificiales es su capacidad de aprender en base a un conjunto de datos, que le sirven de entrenamiento para encontrar un modelo que se ajuste a los datos.

Existen dos tipos de aprendizaje para las redes neuronales en primer lugar tenemos el aprendizaje supervisado: en este tipo de aprendizaje existe un supervisor de la red, este supervisor conoce la salida deseada del sistema, para conseguir esta salida exitosa el supervisor tiene la habilidad de modificar las entradas para conseguir que la salida se aproxime a la deseada. En el aprendizaje supervisado suelen considerarse los aprendizajes supervisados como: Aprendizaje por corrección de error, aprendizaje por refuerzo o aprendizaje estocástico. Aprendizaje no supervisado (auto supervisado): Las redes neuronales artificiales con aprendizaje no supervisado, no requieren supervisión externa para ajustar los pesos de sus neuronas, la red no recibe información referente a si la salida del sistema es o no es correcta. Estas redes buscan características, patrones, correlaciones o categorías que pueda establecerse entre los datos de entrada. La salida de estas redes depende completamente de la estructura de la red, tanto como del algoritmo de aprendizaje empleado (Matich, 2001).

2.13 Aprendiz de clasificación Matlab

Matlab es un lenguaje de programación, diseñado para la computación técnica, el nombre proviene de las palabras Matrix LABoratory, esencialmente por que el tipo de dato básico es una matriz. Matlab puede ser utilizado en matemática, simulación o modelado de procesos, análisis, visualización y representación de gráficos o el desarrollo de algoritmos. (Gilat, 2006). Una característica de Matlab, es la incorporación de herramientas (toolbox), que son una colección de funciones especializadas que extiende significativamente el uso de funciones incorporadas en el programa base. Acerca de los toolbox algunos de los más destacados son los enfocados al procesamiento de imágenes, señales y sistemas, control robusto, matemáticas financieras, lógica difusa, simulación de sistemas dinámicos, redes neuronales (Cheje, 2008). La toolbox Aprendiz de clasificación (Classification learner), es una herramienta destinada a la clasificación de datos, con ella podemos explorar el aprendizaje automático supervisado con varios clasificadores. Entre sus posibilidades de configuración tenemos: configurar los esquemas de validación, entrenar modelos y seleccionar características. Al mismo tiempo podemos encontrar algunos modelos de clasificación como: árboles de decisión, análisis discriminante, máquinas de soporte vectorial, regresión logística, vecinos más cercanos, clasificadores bayesianos. Para realizar un aprendizaje supervisado, se presenta a la herramienta un conjunto conocido de datos de entrada (mediciones) y respuestas (gesto al que pertenece la medición). Los datos son utilizados para entrenar un modelo de clasificación que genere una predicción para un nuevo dato presentado. (MathWorks, 2020).

2.14 Discriminante lineal

El análisis discriminante lineal (LDA) es una técnica de análisis de múltiples variables que es capaz de aprovechar las relaciones existentes entre una gran cantidad de variables independientes para maximizar la capacidad de discriminar. Es un método útil para el reconocimiento de patrones, donde se busca una combinación lineal de funciones que caracterizan o separan dos o más clases de objetos o eventos (García, Darghan, & Fischer, 2017). Uno de los objetivos del aprendizaje supervisado es utilizar las características de un objeto para identificarlo. Un clasificador lineal toma una combinación lineal de las características de un objeto para decidir su clasificación. Las características del objeto son presentadas al sistema a través de un vector de características.

Capítulo 3. Metodología

La presente metodología se divide en dos secciones, la primera sección denominada algoritmo optimizado para el reconocimiento de enfermedades musculares basado en el análisis de parámetros temporales y coeficientes de correlación describe la creación de un algoritmo en Matlab para la clasificación de tres condiciones médicas en base a sus señales EMG, las cuales fueron recuperadas del portal physionet.org

Parte 1 Algoritmo optimizado para el reconocimiento de enfermedades musculares basado en el análisis de parámetros temporales y coeficientes de correlación

En esta sección se muestra una clasificación de tres condiciones biomédicas en base a sus señales EMG. Dichas señales fueron recuperadas de la base de datos pública Physionet (<https://physionet.org/content/emgdb/1.0.0/>). Cabe señalar que Physionet, es un recurso de investigación para señales fisiológicas complejas establecido en 1999 y auspiciado por institutos nacionales de salud (NIH). Todo el análisis se desarrolló utilizando un procesador Intel® Celeron® a 2.16 GHz. Utilizando Matlab versión R2018a. Los datos fueron recolectados con un sistema de monitoreo EMG Mendelec Synergy N2 (Oxford Instruments Medical, Old Woking, Reino Unido). Se colocó un electrodo de aguja concéntrica de 25 mm en el músculo tibial anterior de cada sujeto. Luego se le pidió al paciente que dorsiflexara suavemente el pie contra la resistencia. El electrodo de aguja se reposicionó hasta que se identificaron los potenciales de la unidad motora con un tiempo de aumento rápido. Luego se recopilaron datos durante varios segundos, momento en el que se le pidió al paciente que se relajara y se le quitó la aguja. La señal recuperada, es una grabación en el tiempo, para facilitar el procesamiento de acuerdo a la literatura, se llevó a cabo una segmentación adyacente. Cada Bioseñal señal se dividió en 20 segmentos adyacentes, cada una con 2000 muestras, dicho procesamiento se realizó para cada condición médica. Los datos se registraron a 50 KHz y luego se redujeron a 4 KHz. Durante el proceso de grabación se utilizaron dos filtros analógicos: un filtro de paso alto de 20 Hz y un filtro de paso bajo de 5 KHz. La señal para la clase 1 (individuo saludable) pertenece a un hombre de 44 años de edad, sin historial de una enfermedad neuromuscular. La clase 2 (Neuropatía) pertenece a un hombre de 62 años de edad, con dolor lumbar crónico y neuropatía debido a una radiculopatía L5 derecha. Finalmente, la clase 3 (Miopatía) pertenece a un hombre de 57 años con miopatía debido a una larga historia de polimiositis, tratado eficazmente con esteroides y dosis bajas de metotrexato. El algoritmo creado en Matlab, fracciona la señal recuperada en

Physionet para cada condición, y crea el ensamble de 20 segmentos, con 2000 muestras cada sub-síñal. La figura 1 muestra el ensamble de la señal EMGs de un individuo saludable.

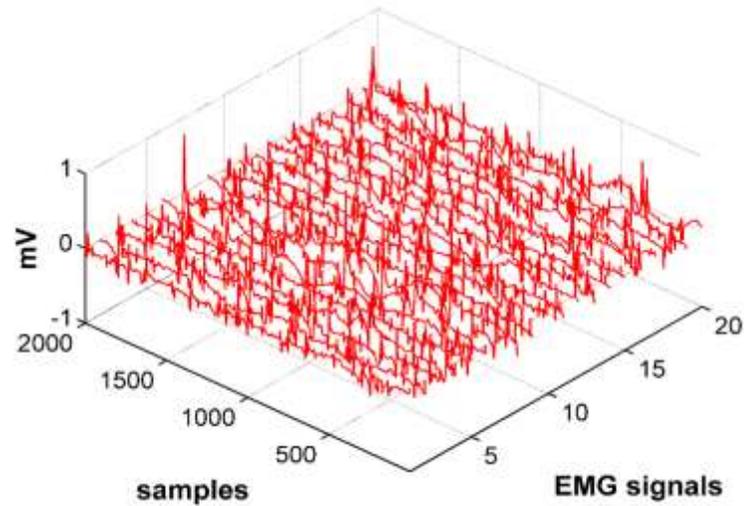


Figura 1 Ensamble de Señal EMG de una persona saludable, 20 sub-señales con 2000 muestras cada una.

Recuperado de (Mejía-González, 2019)

La figura 2 muestra la señal EMGs de un individuo con Miopatía (clase 2).

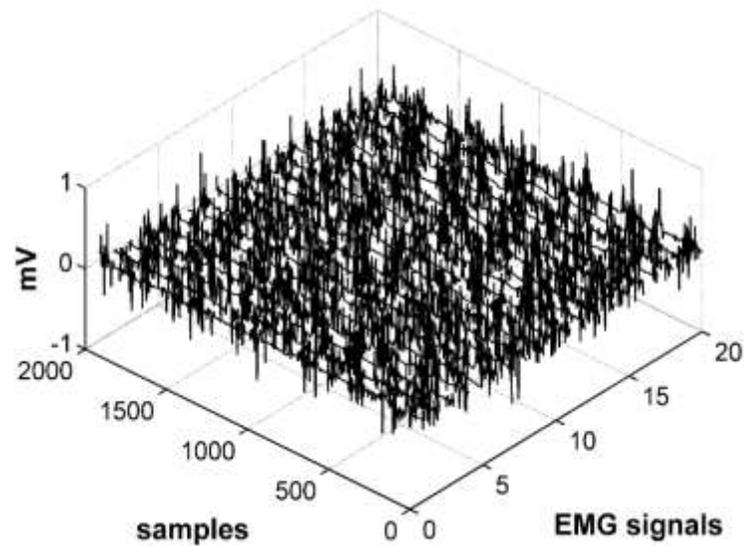


Figura 2 Ensamble de Señal EMG de un individuo con Miopatía., 20 sub-señales con 2000 muestras cada una.

Recuperado de (Mejía -González, 2019)

Finalmente, en la figura 3, vemos el ensamble de los segmentos adyacentes para un individuo con Neuropatía (clase 3).

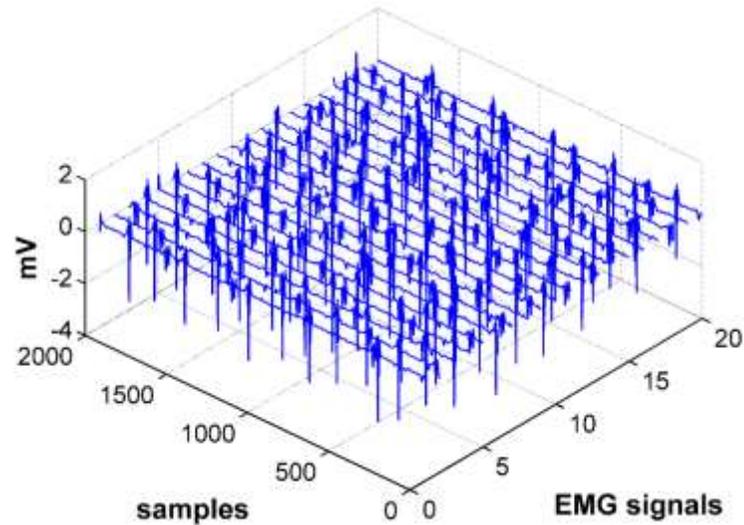


Figura 3 Ensamble de Señal EMG de un individuo con Neuropatía. 20 sub-señales con 2000 muestras cada una. Recuperado de (Mejía -González, 2019)

La figura 4, muestra la señal más representativa de cada condición, se muestran en el mismo gráfico para identificar similitudes y diferencias

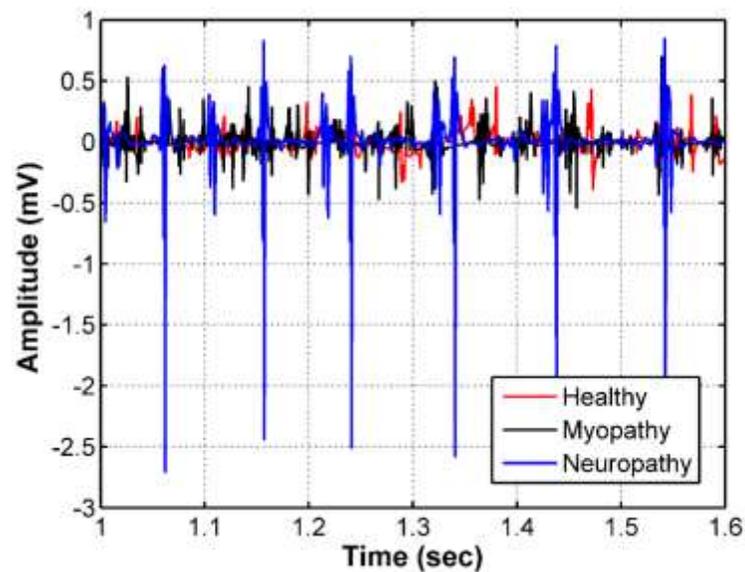


Figura 4 Señal EMG representativa para cada condición médica. (Rojo: saludable. negro: Miopatía. Azul: Neuropatía). Recuperado de (Mejía -González, 2019).

Algunas diferencias entre señales se aprecian claramente en la figura 4, como lo es la amplitud para la señal de la clase 3 (Neuropatía) en comparación con las otras condiciones médicas. Por su parte se ve un incremento de velocidad para Miopatía (clase 2). En Matlab, se diseñó un algoritmo que permitió extraer características en el dominio del tiempo de cada señal. El algoritmo toma un segmento por iteración, obtiene sus características estadísticas definidas por el vector de características y crea una matriz (20 renglones por 14 columnas), en donde cada renglón se forma en el orden definido en el vector de características. Cada matriz creada contiene 20 vectores de características y 14 columnas, cada columna corresponde a un parámetro estadístico. El vector de características se formó a través de la extracción de parámetros estadísticos en el dominio del tiempo de cada segmento de cada clase. El vector de características (VC) queda definido de la siguiente manera:

$VC = [Mediana, Valor\ cuadrático\ medio\ (RMS), Varianza, curtosis, Oblicuidad, Rango\ intercuartil\ (IQR), Cuartil\ 1\ (Q1), Cuartil\ 2\ (Q2), Cuartil\ 3\ (Q3), Percentil\ 10, Percentil\ 20, Percentil\ 50, percentil\ 70, percentil\ 90]$.

Una vez creada la matriz, el algoritmo calcula el promedio de cada parámetro estadístico, para crear un solo vector de características por cada clase. Este vector de características es utilizado para entrenar el algoritmo y enseñarle a identificar cada clase. La figura 5 muestra el vector de características para la clase #1.

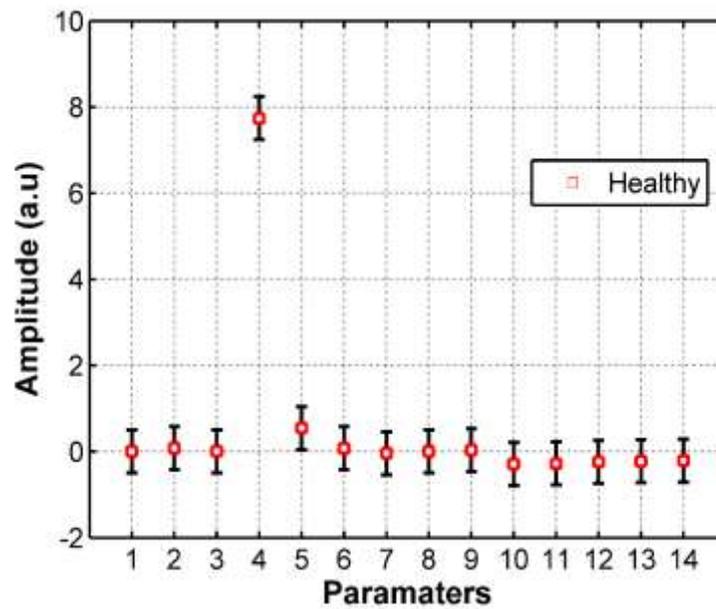


Figura 5 Vector de características de la señal EMG de una persona saludable. Recuperado de (Mejía -González, 2019)

La figura 6 muestra el vector de características para la clase #2.

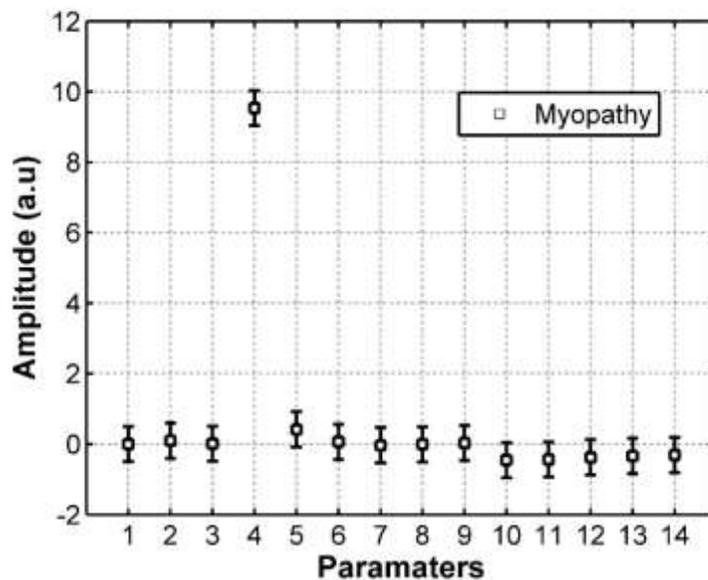


Figura 6 Vector de características de la señal EMG de Miopatía Recuperado de (Mejía- González, 2019)

La figura 7 muestra el vector de características para la clase #3.

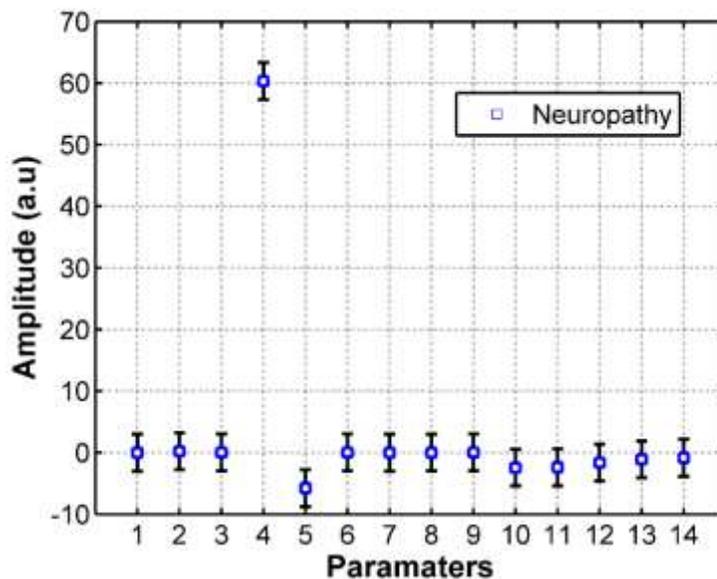


Figura 7 Vector de características de la señal EMG Neuropatía Recuperado de (Mejía -González, 2019)

Después de la creación el vector de características, el algoritmo es entrenado y evaluado para examinar su desempeño. Para probar el desempeño del clasificador creado, el algoritmo toma una señal aleatoria de la base de datos de 60 señales, que comprende 20 segmentos por cada gesto, esta señal aleatoria sirve de entrada para el algoritmo. El algoritmo recibe la señal de entrada, obtiene el vector de características,

y compara cada parámetro estadístico con los valores de las condiciones médicas. Los resultados obtenidos se discuten en el apartado de resultados.

Parte 2 (Reconocimiento automático para gestos de pierna basado en lector de Electromiografía Portable)

La parte 2 de la metodología describe el diseño de la puesta en marcha de un Electromiógrafo para la obtención de una EMGs del músculo Vasto Intermedio, para su posterior tratamiento y clasificación de las acciones caminar, correr, subir escaleras y bajar escaleras. La figura 8 muestra la implementación del hardware requerido en la adquisición de las señales EMG del músculo Vasto intermedio. Para las acciones: caminar, correr, subir escaleras y bajar escaleras.

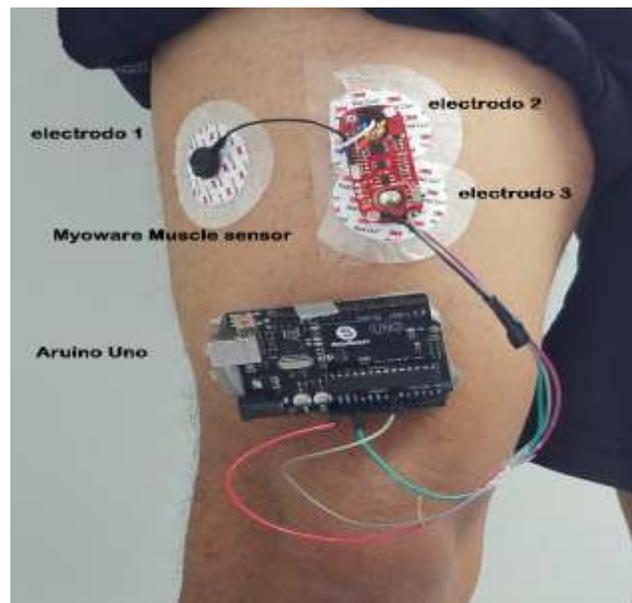


Figura 8 Arreglo del Hardware utilizado en la adquisición de datos.

Los electrodos utilizados pertenecen a la marca 3M™ Red Dot™ Electrodo de monitorización pediátrica con soporte de cinta 3M™ Micropore™ 2248, se adquirió la bolsa con 50 unidades. Es conveniente mencionar que el uso de la versión pediátrica es la más adecuada de acuerdo a las recomendaciones dadas por SENIAM Project (Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles) programa enfocado a homologar la posición a situar electrodos en diferentes músculos, de acuerdo al motivo de estudio. Por su parte la instrumentación encargada de la Electromiografía fue el sensor muscular de la marca MyoWare™ Muscle Sensor (AT-04-001), quien permite obtener una señal filtrada y rectificada, el uso y aplicación estuvo sujeta a la hoja de datos del producto. Cabe señalar, que el acomodo de los electrodos en el músculo vasto intermedio se llevó de acuerdo a las especificaciones recomendadas por

SENIAM. La adquisición de los datos arrojados por Myoware, estuvo a cargo de Arduino uno. Así mismo el procesamiento de todos los datos se llevó a cabo en Matlab versión r2018a.

El Algoritmo clasificador de las señales EMG para las condiciones médicas (sujeto saludable, Miopatía, Neuropatía) se reutiliza en este apartado, para el fraccionamiento de la señal, y la extracción de características. Sin embargo, aquí se encuentra la primera modificación al algoritmo original, se realizó un pre-procesamiento de la señal para eliminar distorsión y elementos no requeridos de la señal, como los ocasionados al inicio y al final de la medición. Teniendo en cuenta que la grabación de la señal por cada acción fue continua en el tiempo, fue necesario identificar picos de amplitud (figura 9), para poder identificar el periodo óptimo de una acción en particular, como **un solo paso, en la caminata**.

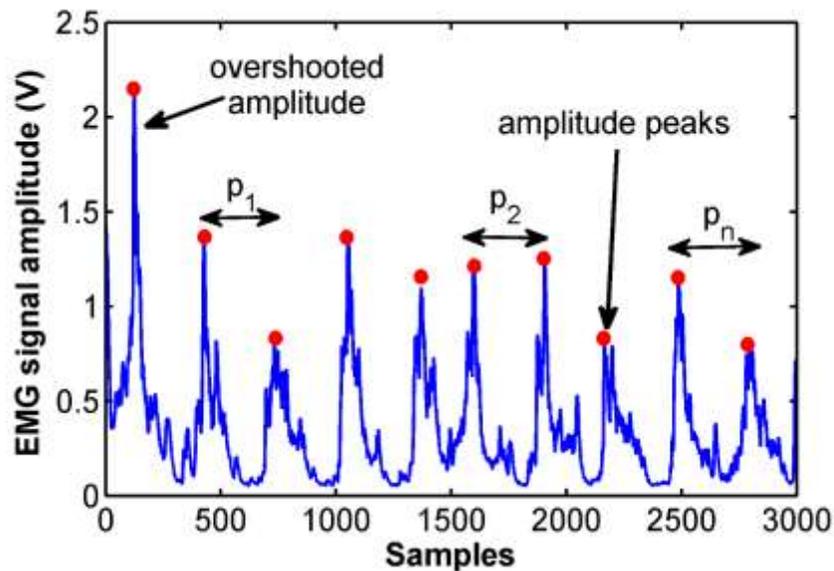


Figura 9 Señal representativa, para el gesto bajar escaleras, pierna derecha (Amplitud contra muestras)

Para calcular el periodo promedio de una acción en particular, por ejemplo, un paso en la caminata, utilizamos la ecuación 7. En donde \bar{t}_p es el promedio del periodo de una clase en particular. m es el valor de la amplitud de los valores máximos locales, denominados picos de amplitud.

$$\bar{t}_p = \frac{1}{m-1} \sum_{n=2}^m (p_n - p_{n-1}) \quad (7)$$

Por consiguiente, se obtuvo un ensamble de 10 segmentos adyacentes por cada gesto, de forma tal que se obtuvo una grabación similar a la figura 10 por cada gesto. En la figura 10 se muestra en ensamble obtenido, para los segmentos de la señal EMG bajar escaleras. Es importante mencionar que se siguieron protocolos específicos, para que la señal fuera lo más homogénea posible, teniendo en cuenta que las mediciones se llevaron en tiempo real, hay factores externos difíciles de controlar, gracias a esto podemos

notar factores diferentes entre las señales, pero que arrojan gran cantidad de información para la acción en la vida real. En la figura 10, se muestran señales con retraso, una en específico con una amplitud diferente, y el resto de datos caen en el perfil correcto de la señal.

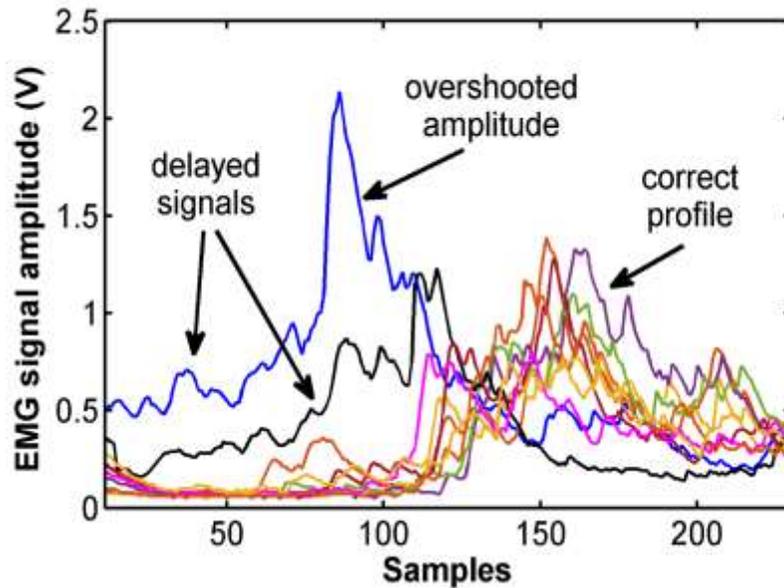


Figura 10 Ensamble de las señales EMG para el gesto Bajar escaleras. (Amplitud contra muestras) Clase #1.
Muestras contra amplitud

La figura 11 muestra el ensamble de los segmentos adyacentes de la señal EMG para subir escaleras denominada clase #2.

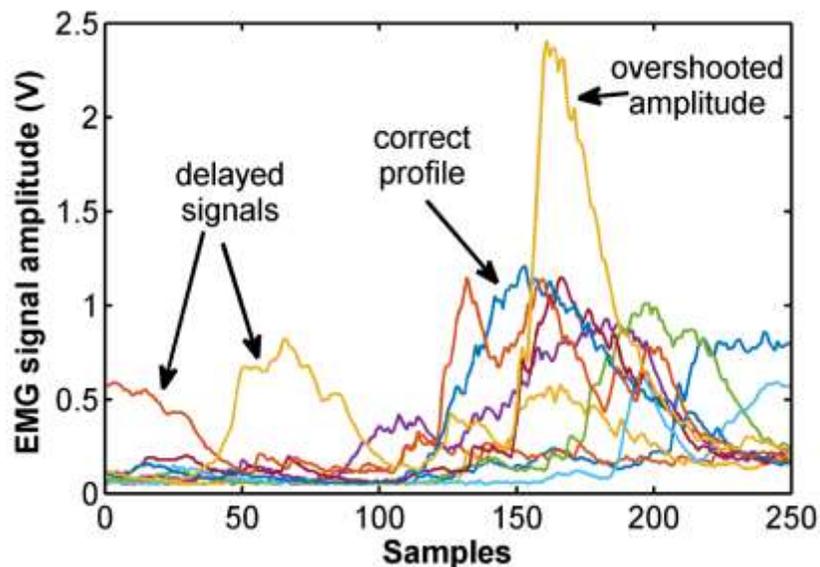


Figura 11 Ensamble de la señal EMG para subir escaleras clase #2. Muestras contra amplitud

La figura 12 muestra el ensamble de los segmentos de la señal EMG para caminar denominada clase #3

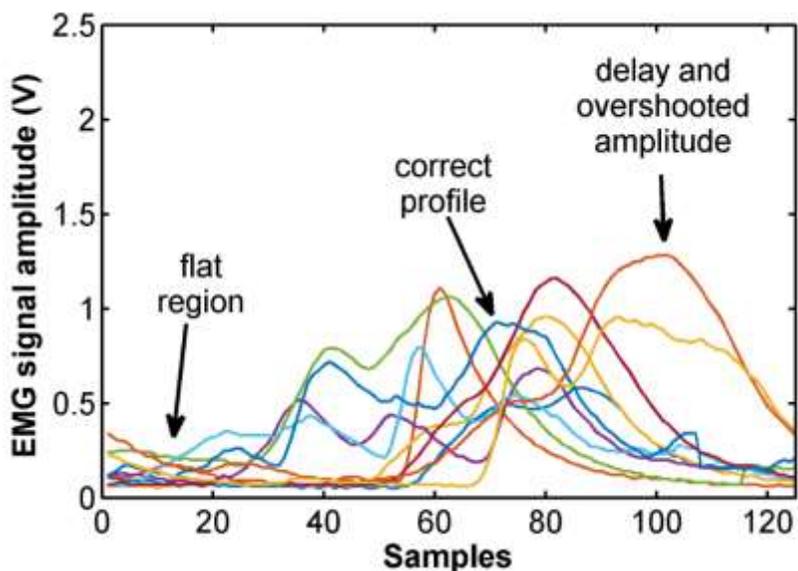


Figura 12 Ensamble de la señal EMG para caminar clase #3. Muestras contra amplitud

La figura 13 muestra el ensamble de los segmentos adyacentes de la señal EMG para correr denominada clase #4

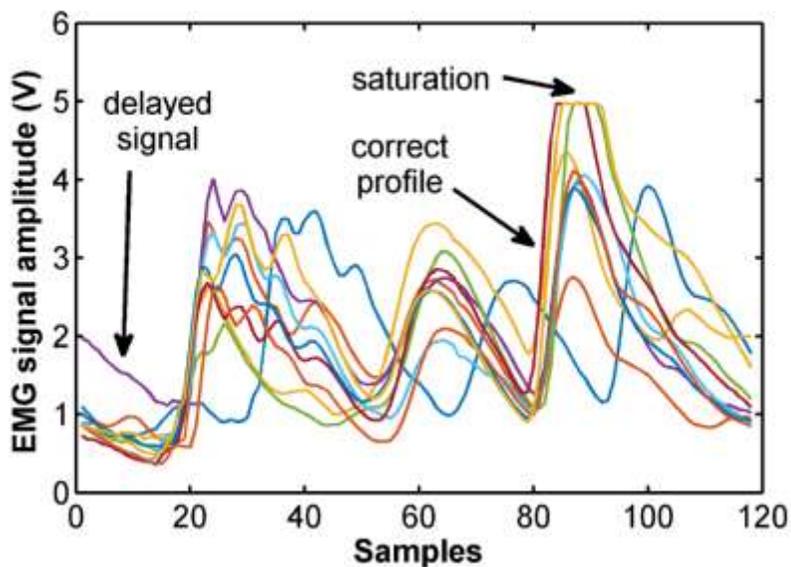


Figura 13 Ensamble de la señal EMG para correr clase #4. Muestras contra amplitud

Un aspecto importante, para el gesto correr, es la saturación que se presenta, misma que no aparece en ningún ensamble de las clases anteriores. Los ensambles muestran diferencias notables para cada gesto,

cada uno es diferente en frecuencia, amplitud y tiempo, al igual que cada una presenta un perfil muy diferente a las demás.

Con el ensamble de las señales, el algoritmo calcula el vector de características basado en parámetros temporales de cada segmento adyacente para cada condición biomédica y crea una matriz de 20 renglones con 20 columnas, en donde cada renglón es un vector de características y cada columna corresponde a un parámetro estadístico.

El vector de características queda definido:

VC= [Mediana, Varianza, curtosis, Oblicuidad, Rango intercuartil (IQR), Cuartil 1 (Q1), Cuartil 2 (Q2), Cuartil 3(Q3), Percentil 10, Percentil 20, Percentil 50, percentil 70, Percentil 90, RMS, Desviación estándar, Mediana, Máximo, Moda, Mínimo, Rango].

Una vez formado el vector de características de cada segmento, se calcula el vector de características del arreglo de segmentos. El vector de características de todo el ensamble de segmentos, es utilizado para entrenar el algoritmo clasificador. En Matlab se hace uso de la aplicación Classification Learner para entrenar y validar el algoritmo de clasificación. Los resultados obtenidos de las clasificaciones realizadas con la aplicación de Matlab se discuten en el apartado de resultados.

Capítulo 4. Resultados y Discusión

Parte 1

La parte de 1 describe los resultados para la metodología: Algoritmo optimizado para el reconocimiento de enfermedades musculares basado en el análisis de parámetros temporales y coeficientes de correlación, la cual expone la clasificación de las señales EMG de tres condiciones médicas para: un sujeto saludable, un sujeto con miopatía y un sujeto con Neuropatía

Con los vectores construidos que se muestran en las figuras 5,6 y 7. El algoritmo desarrollado fue puesto a prueba para examinar su desempeño. La señal de prueba se creó aleatoriamente, para la clase y el segmento. Esta señal aleatoria creada, sirvió de entrada para el algoritmo permitiéndole al algoritmo diferentes tolerancias: $\pm 20\%$, $\pm 10\%$ y $\pm 5\%$. Estos umbrales fueron definidos solo como objetivos técnicos, para evaluar el desempeño del algoritmo. Sin embargo, la tolerancia debe modificarse para aplicaciones médicas reales.

El análisis del desempeño del algoritmo se evaluó con diagramas de caja creadas en Matlab. La figura 14 muestra el desempeño del algoritmo tomando como una entrada una sub-señal para la clase 1, y una tolerancia de $\pm 20\%$. La pertenencia a la clase uno, es un dato fijo del algoritmo, como siguiente paso el algoritmo genera números aleatorios del 1 al 20, en el cual cada uno corresponde a un segmento de cada condición. Debido a esto esperamos que la mayor probabilidad de pertenencia a un gesto corresponda a la clase 1.

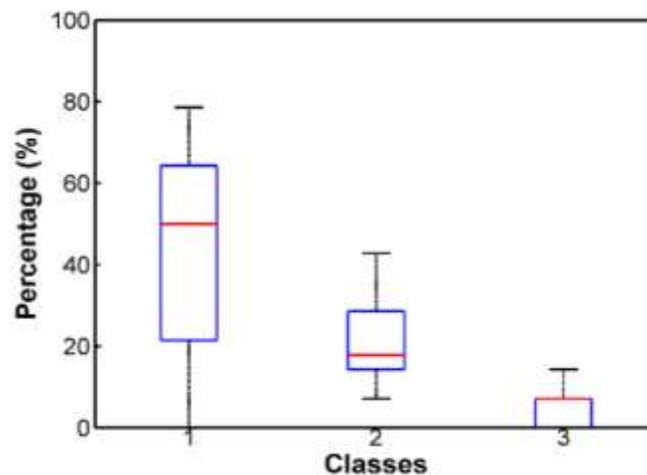


Figura 14 Desempeño del algoritmo para la clase uno, con una tolerancia de $\pm 20\%$.

Dentro de los parámetros estadísticos que podemos observar en la gráfica de caja tenemos: la mediana se encuentra en 50%, el primer cuartil en 21.4%, el tercer cuartil en 64.2% el valor máximo es 78.8%, el valor

mínimo y el rango inter- cuartil se encuentran en 42.8%. Hay que mencionar además la probabilidad para las clases 2 (mediana: 17.8) y 3 (mediana: 17.8). Y el valor inter-cuartil decrece.

La figura 15 muestra el desempeño del algoritmo tomando en cuenta solo un segmento aleatorio para la clase 2. Aquí podemos observar que el porcentaje máximo de reconocimiento del algoritmo para la señal aleatoria de la clase 2 es de 85.7%.

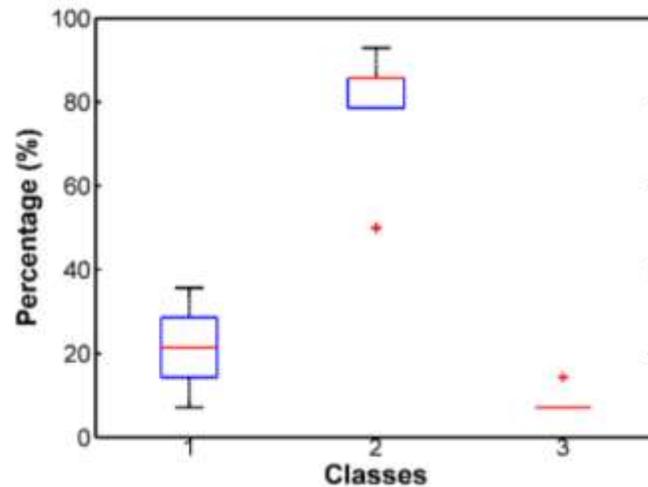


Figura 15 Gráfica de caja que muestra el desempeño del algoritmo para la clase 2, con una tolerancia de $\pm 20\%$.

La figura 16 muestra el desempeño del algoritmo para la señal aleatoria de la clase 3 (85.7%)

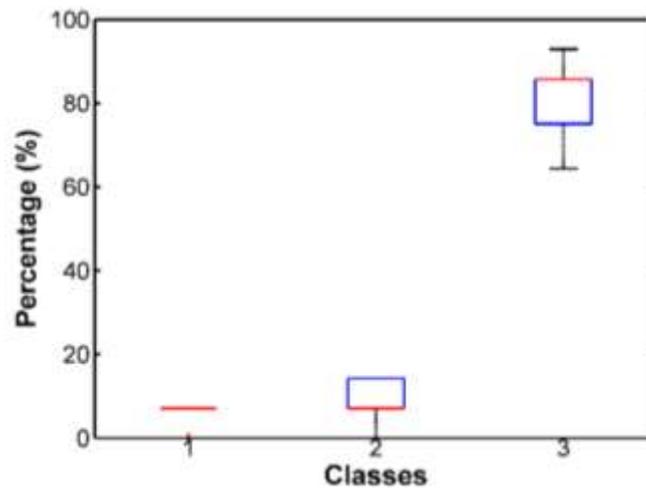


Figura 16 Gráfica de caja que muestra el desempeño del algoritmo para la clase 3, con una tolerancia de $\pm 20\%$.

El siguiente aspecto trata de la reducción de la tolerancia de clasificación a $\pm 10\%$. La figura 17 muestra el diagrama de caja para la clasificación de una señal aleatoria de la clase 1, con una tolerancia de $\pm 10\%$.

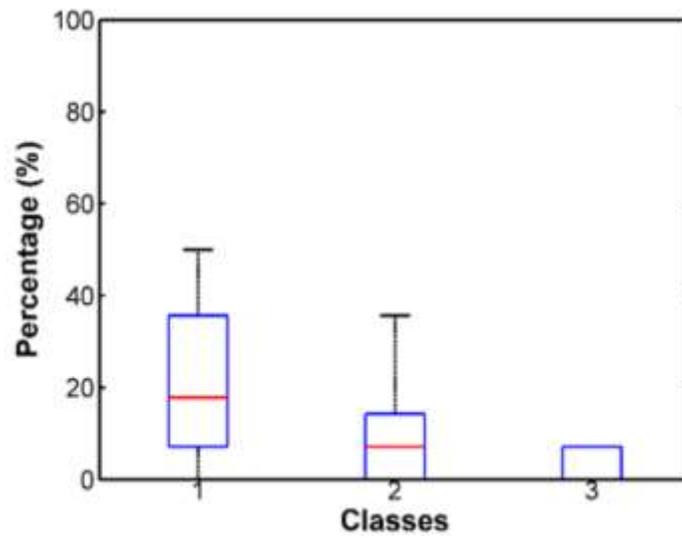


Figura 17 Diagrama de caja del rendimiento del algoritmo para la clase 1, considerando una tolerancia de $\pm 10\%$.

La figura 18 muestra el diagrama de caja para la clasificación de una señal aleatoria de la clase 2, con una tolerancia de $\pm 10\%$.

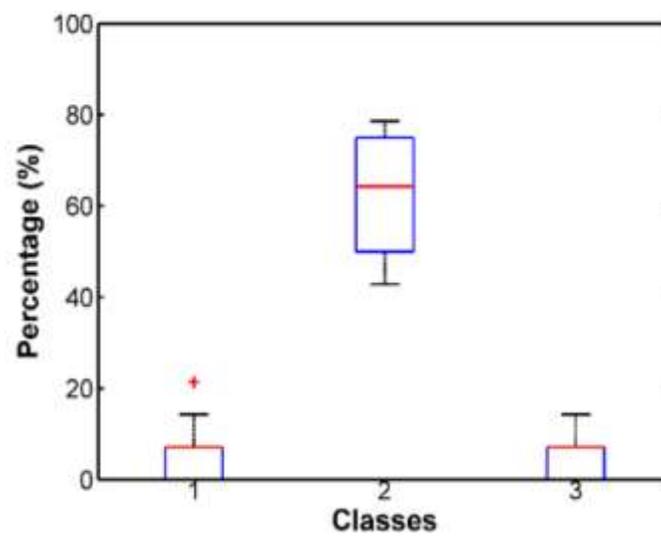


Figura 18 Diagrama de caja del rendimiento del algoritmo para la clase 2, considerando una tolerancia de $\pm 10\%$.

La figura 19 muestra el diagrama de caja para la clasificación de una señal aleatoria de la clase 3, con una tolerancia de $\pm 10\%$.

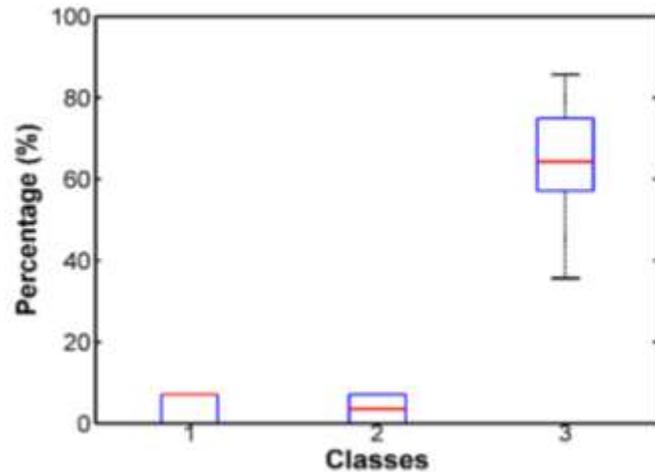


Figura 19 Diagrama de caja del rendimiento del algoritmo para la clase 3, considerando una tolerancia de $\pm 10\%$.

Teniendo en cuenta que cuando se considera una señal aleatoria de cada clase, la gráfica de caja nos muestra que la pertenencia (mediana) a cada clase es la correcta. Por ejemplo, al considerar una señal aleatoria perteneciente a la clase 1, la mayor probabilidad de pertenencia mostrada en la gráfica de caja, corresponde a la clase 1, mientras que la probabilidad de pertenencia a otra clase es menor. Se debe agregar que el algoritmo fue evaluado para una tolerancia menor, en esta ocasión $\pm 5\%$. Con las mismas consideraciones expresadas anteriormente. La figura 20 muestra el diagrama de caja para la clasificación de una señal aleatoria de la clase 1, con una tolerancia de $\pm 5\%$.

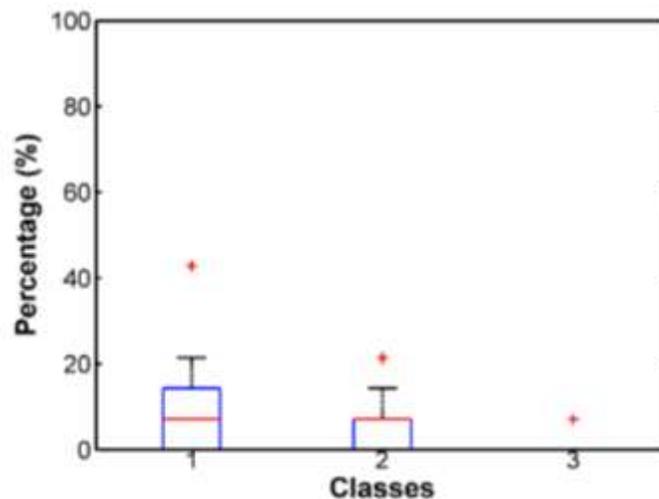


Figura 20 Diagrama de caja del rendimiento del algoritmo para la clase 1, considerando una tolerancia de $\pm 5\%$.

La figura 21 muestra el diagrama de caja para la clasificación de una señal aleatoria de la clase 2, con una tolerancia de $\pm 5\%$.

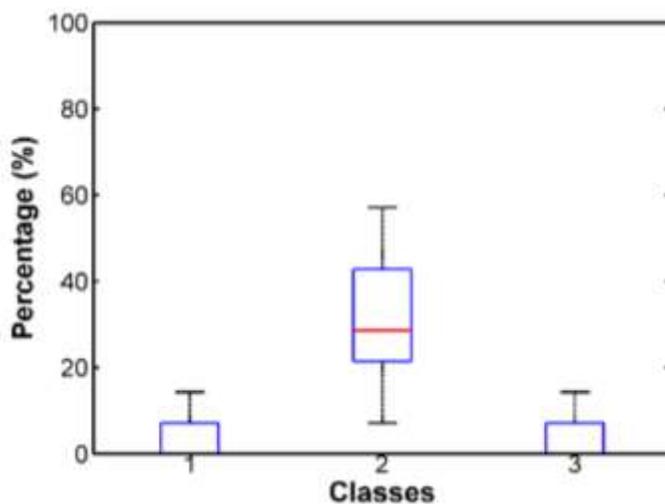


Figura 21 Diagrama de caja del rendimiento del algoritmo para la clase 2, considerando una tolerancia de $\pm 5\%$.

La figura 22 muestra el diagrama de caja para la clasificación de una señal aleatoria de la clase 3, con una tolerancia de $\pm 5\%$.

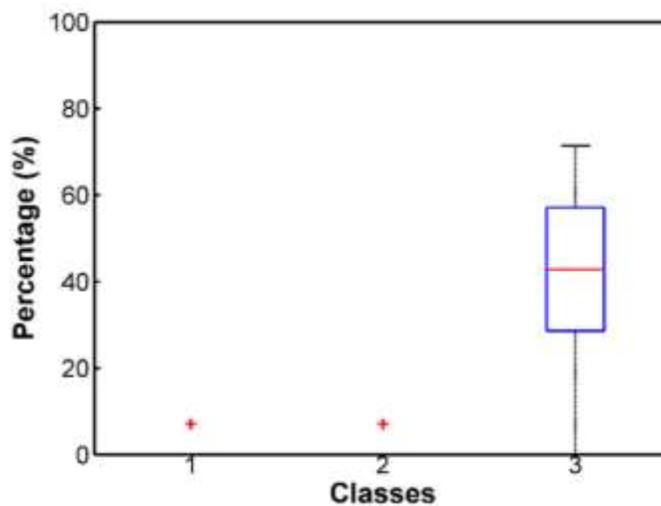


Figura 22 Diagrama de caja del rendimiento del algoritmo para la clase 3, considerando una tolerancia de $\pm 5\%$.

Con las gráficas presentadas es posible observar que la clasificación y el proceso de reconocimiento son correctos bajo ciertas consideraciones estadísticas. Con esto quiero decir, que la probabilidad máxima siempre pertenece a la clase correcta. El siguiente aspecto trata de un vector de características optimizado. Basado en los coeficientes de correlación para todas las clases utilizadas por el algoritmo. Cabe mencionar que los resultados presentados, están basados en el vector de características propuesto, el cual contiene

las 14 características. En primer lugar, se calcula la correlación de coeficientes para cada clase. La figura 23 muestra la correlación de coeficientes para la clase 1.

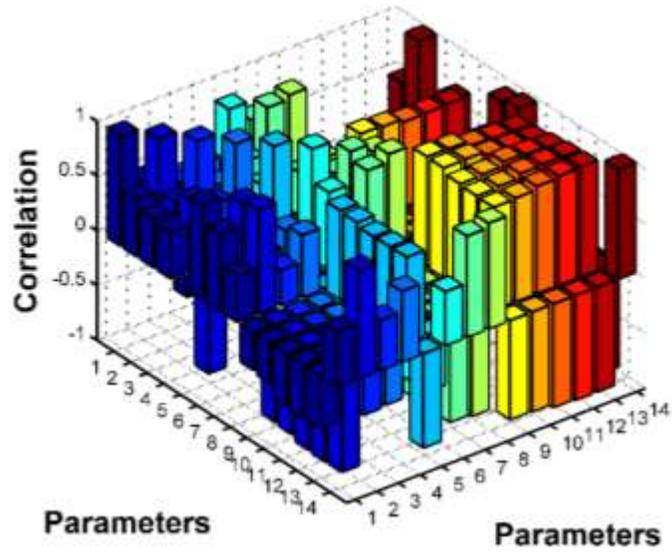


Figura 23 muestra la correlación de coeficientes para la clase 1.

La figura 24 muestra la correlación de coeficientes para la clase 2.

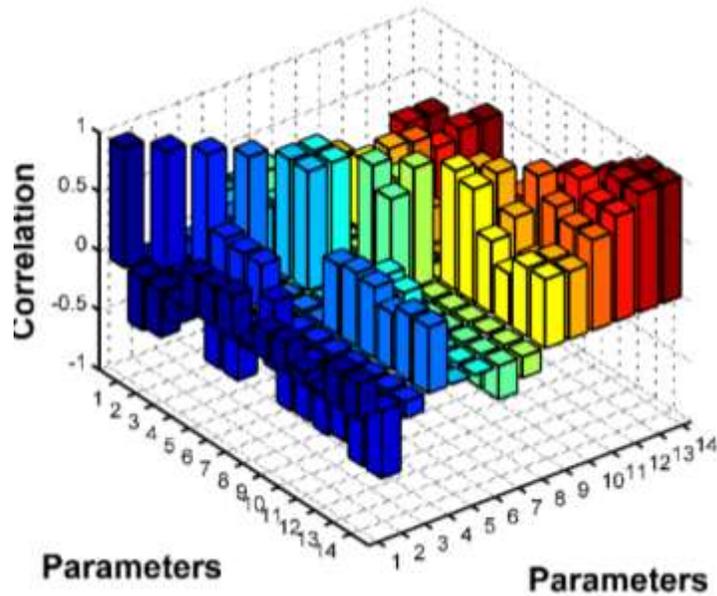


Figura 24. Correlación de coeficientes para la clase 2

La figura 25 muestra la correlación de coeficientes para la clase 3.

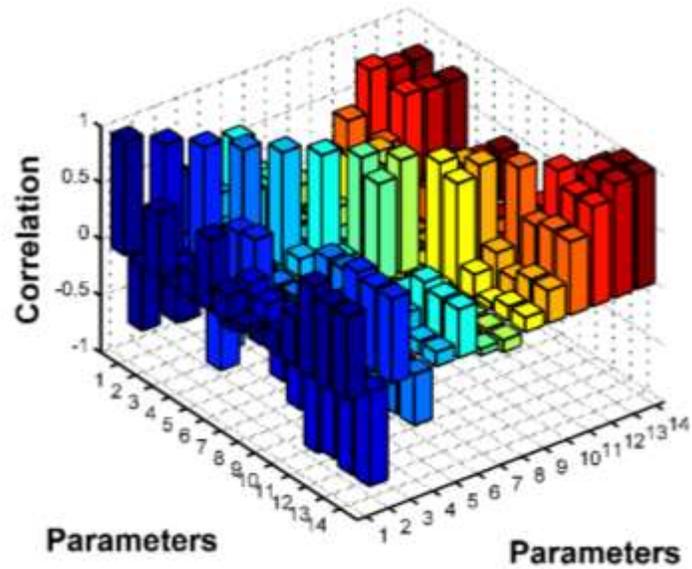


Figura 25 Correlación de coeficientes para la clase 3

Es conveniente recordar que la diagonal principal no aporta datos, ya que representa la autocorrelación de los parámetros, por eso estos valores siempre son 1. La figura 26 muestra la correlación de los coeficientes para todas las clases.

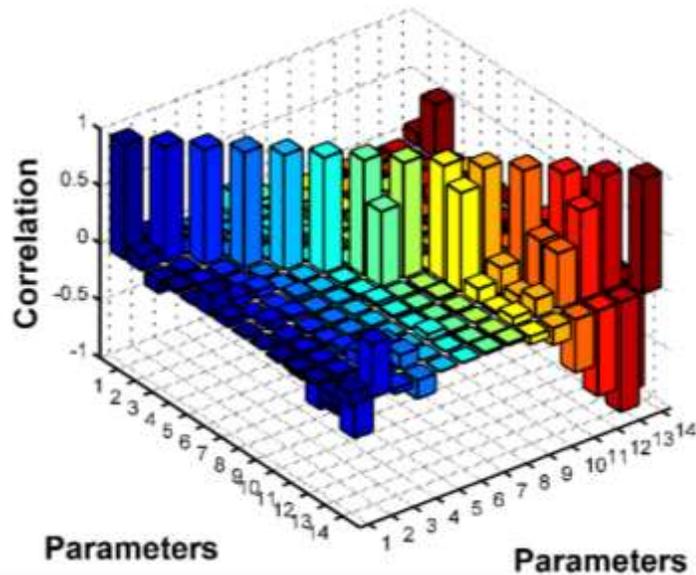


Figura 26 Correlación de coeficientes para todas las clases

Basado en la correlación, se determinaron aquellos parámetros temporales que tienen mayor aportación a la clasificación y se descartaron aquellos que no aporta información y solo consumen recursos computacionales. Por consiguiente 9 parámetros fueron seleccionados para realizar la optimización del vector de características.

La figura 27 muestra los resultados para una señal aleatoria de la clase 1, considerando el vector de características optimizado.

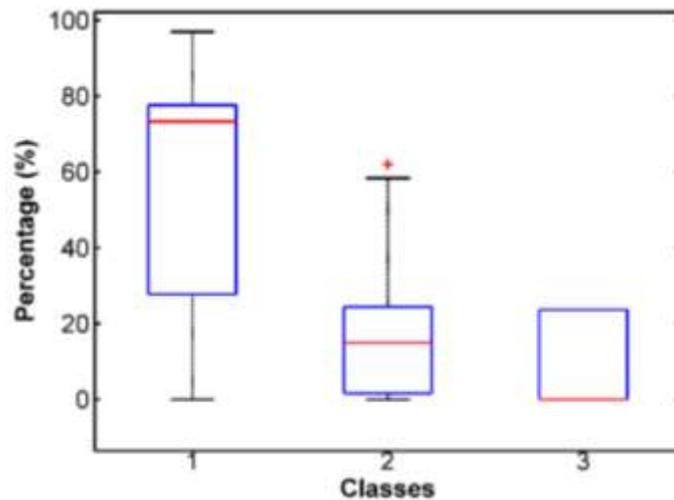


Figura 27 Desempeño del algoritmo, con el vector de características optimizado para la clase 1

Como se puede observar todos los parámetros estadísticos mejoraron. La mediana para la clase 1 es de 75% la clasificación basada en el vector no optimizado fue de 50%. Figura 15 y la probabilidad de pertenencia a otra clase disminuye. Finalmente, la figura 28 muestra el tiempo requerido por el algoritmo para sus etapas de entrenamiento y reconocimiento. 200 y 4 milisegundos en promedio respectivamente. Lo cual es de suma importancia para futuras aplicaciones.

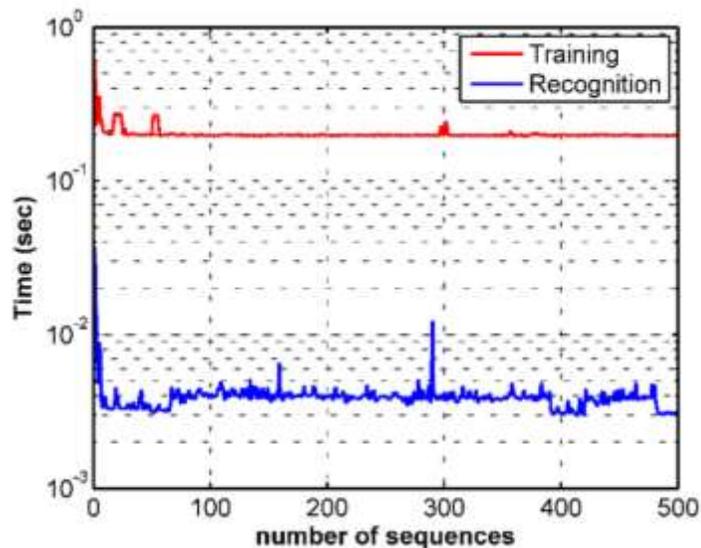


Figura 28 Tiempo requerido por el algoritmo para su entrenamiento y clasificación de las condiciones fisiológicas.

Parte 2

En esta sección se describen los resultados para la metodología denominada: Reconocimiento automático para gestos de pierna basado en lector de Electromiografía Portable, la cual describe la clasificación de las señales obtenidas para las acciones caminar, correr, subir escaleras y bajar escaleras. Con los ensambles creados con la obtención de los gestos (figuras 10, 11, 12 y 13) caminar, correr, subir escaleras y bajar escaleras, se obtuvo el vector de características. En Matlab la aplicación de entrenamiento de clasificación (Classification Learner App) fue utilizada para validar el algoritmo. Consideramos un modelo de clasificación específico, el modelo Análisis de discriminante lineal (Linear Discriminant Analysis LDA). Considerando como señal de entrada todas las clases y la definición de un problema multiclase. La figura 29, muestra el desempeño del algoritmo de una manera visual. Llamada matriz de confusión.

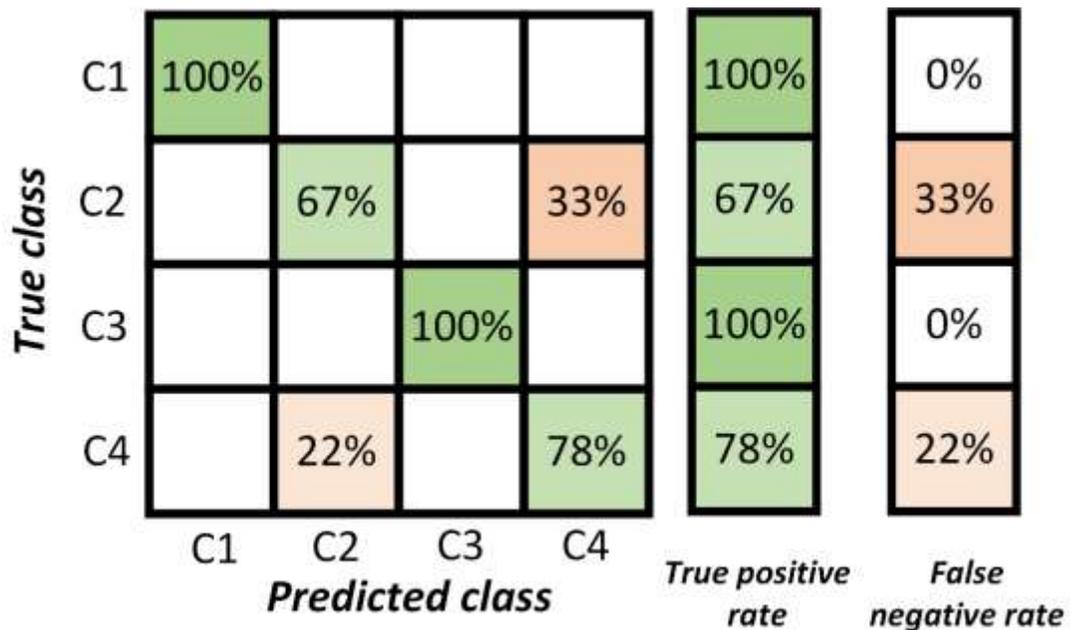


Figura 29 Matriz de confusión para todas las clases.

Por consiguiente, la matriz de confusión muestra que la clase 1 y la clase 3 (los gestos bajar escaleras y caminar, respectivamente) tienen una exactitud de clasificación del 100%. La muestra aleatoria de entrada al clasificador siempre se clasifica en la clase correcta. Por otro lado, la clase 2 tiene una exactitud del 67% y en proporción un error del 33%. Es importante mencionar que el algoritmo presenta una confusión de las clases clase 2 (subir escaleras) y la clase 4 (correr). La confusión solo se presentó en las clases 2 y 4, para todas las corridas del programa. En particular, la tasa de falso negativo (FNR False Negative Rate) es un parámetro útil para describir la probabilidad de la hipótesis nula para una clase en particular, es decir muestra las entradas erróneas a la clase a clasificar que se clasifican como correctas.

La figura 30 muestra la Curva característica operativa del receptor (Receiver Operating Characteristic (ROC)) que describe el desempeño del clasificador, solamente para la clase 2 y 4. Las clases 1 y 3 no se presentan, ya que presenta 100% de exactitud.

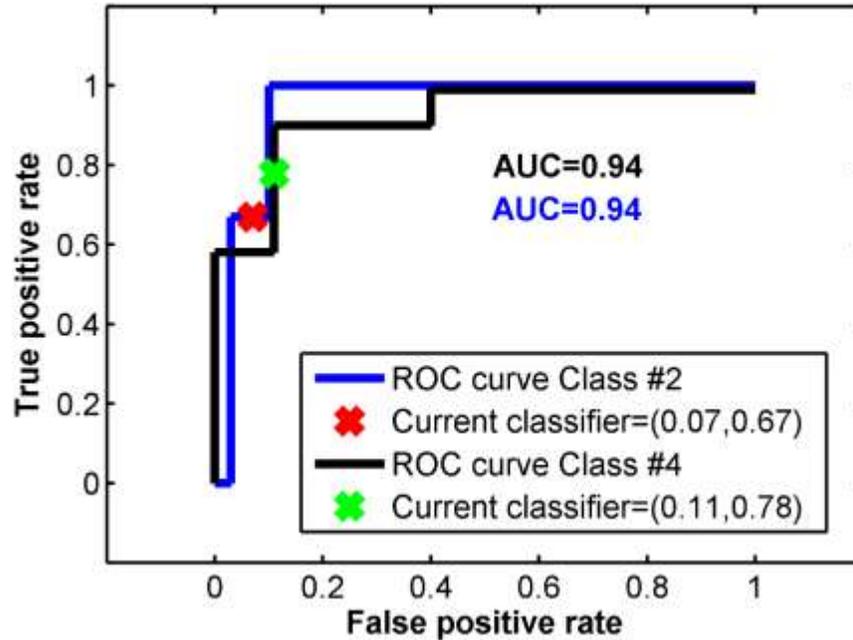


Figura 30 Curva ROC para las clases 2 y 4.

Los valores para el desempeño del clasificador para la clase 4 (Línea negra en la curva ROC) son 0.11 y 0.78 para el falso positivo y el verdadero positivo (respectivamente). En contraste con la clase 2 que presenta valores sutilmente menores. Un aspecto importante que muestra la figura 8 es el Área bajo la curva (AUC) para las clases 2 y 4, son los mismos valores, lo cual quiere decir que el clasificador tiene el mismo desempeño para ambas clases. Así mismo el valor AUC para las clases 1 y 3 es AUC=1.

Capítulo 5. Conclusiones

Parte 1

La parte 1 de la tesis desarrolla la clasificación de 3 condiciones médicas en base a sus señales EMG, las señales fueron recuperadas del sitio Physionet.org (figuras 1, 2 y 3), el vector de características está constituido por parámetros temporales, el primer vector construido constaba de 14 parámetros estadísticos. La primera evaluación de clasificación realizada con los 14 parámetros temporales arrojó el valor más bajo de la clasificación para la clase del sujeto saludable con tan solo el 50% de eficiencia, la mitad de clasificaron de las señales era incorrecta. Es por estos valores que se buscó incrementar el porcentaje de clasificación. La optimización se desarrolló basado en los coeficientes de correlación entre todas las condiciones médicas, para comprender mejor qué parámetros temporales no contribuyen a la clasificación y solo consumen recursos computacionales. Por esta razón se descartaron 5 parámetros del vector de características inicialmente propuesto (14 parámetros) y el vector de características optimizado se redujo a 9 parámetros, hecho que llevó a mejorar la probabilidad de pertenencia a cada clase, y disminuyendo el uso de los recursos computacionales. La mediana de la clasificación para la clase 1 tuvo un incremento favorable quedando en 75% con el vector de características optimizado. La clasificación fue exitosa para las condiciones y tolerancias utilizadas. El reconocimiento de cada clase fue exitoso mostrándose en la máxima probabilidad de pertenencia a la clase correcta. No obstante, el algoritmo debe mejorarse para poder considerar su uso en aplicaciones biomédicas reales. En trabajos futuros se contempla considerar los parámetros frecuenciales en la creación del vector de características y utilizar redes neuronales para para incrementar el desempeño del clasificador, sin incrementar los requerimientos de cómputo y los tiempos de respuesta.

Parte 2.

La parte 2 de la tesis describe la implementación de un Electromiógrafo para la obtención de las señales EMGs para las acciones caminar, correr, subir escaleras y bajar escaleras. Se presentó una técnica para el reconocimiento de gestos de la pierna basado en EMGs y en un análisis de discriminante lineal. Los resultados obtenidos basados en la Matriz de confusión son satisfactorios ya que las clases 1 y 4 muestran un 100% de eficiencia en la clasificación una eficiencia del 67% para la clase 2, por último, para la clase 3 una eficiencia del 78%. La Curva característica operativa del receptor muestra que el LDA tiene el mismo

margen de error con las clases 2 y 4. Cabe señalar que, aunque la clasificación es exitosa, es necesario implementar una optimización para poder ser considerado para condiciones reales y en base a los usuarios finales. En concreto, el monitoreo de las señales EMGs de ambas piernas puede mejorar el rendimiento de prótesis basadas en el análisis de la velocidad y aceleración de las articulaciones inferiores.

Bibliografía

- Álvarez Fiallo, R. S. (19 de agosto de 2006). *Desarrollo histórico y fundamentos teóricos de la electromiografía como medio diagnóstico*. Obtenido de Revista Cubana de Medicina Militar: e http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S0138-65572006000400008&Ing=es&tIng=pt.
- Andrade, M. M. (2011). Prótesis Transfemoral Electromecánica, *INGE@ UAN-Tendencias en la Ingeniería*, 2(3).
- BBC. (27 de JULIO de 2007). *BBC NEWS*. Obtenido de BBC NEWS: http://news.bbc.co.uk/hi/spanish/science/newsid_6919000/6919728.stm
- Butler, D. s. (2002). *Movilización del sistema nervioso*. Barcelona: Paidorribo.
- Caballero, K. D. (2002). Conceptos básicos para el análisis electromiográfico. *Ces Odontología*, 41-50.
- Cabezas, F. A. (2018). Clasificación de señales EEG usando LDA y QDA aplicado a una Interface Cerebro-Computador basada en P300. *TECNIA*, 28(2).
- Carino-Escobar, R. I.-N.-M. (2016). Decodificación de imaginación motora en la señal de electroencefalografía mediante mapas auto-organizados. *Revista del Centro de Investigación. Universidad La Salle*, 107-125.
- Cheje, R. W. (2008). MatLab & Redes Neuronales. *Revistas Bolivianas*, 96-102.
- Correa-Figueroa, J. L.-S.-R.-B.-P. (2016). Sistema de adquisición de señales SEMG para la detección de fatiga muscular. *Revista mexicana de ingeniería biomédica*, 17-27.
- D, S. M; Lugo-González, & Arias-Montiel, M. (2017). Diseño de un Prototipo de Exoesqueleto para Rehabilitación del Hombro. *Revista Mexicana de ingeniería Biomédica*, 330-342.
- E.J. Rechy-Ramírez y H. Hu. (2011). "Stages for developing control systems using EMG and EEG signals: a survey". *School of Computer Science and Electronic*, Informe técnico CES-513.
- Fernández Vázquez, J. M. ((2006)). Guillaume Benjamín Amand Duchenne (1806-1871) "El padre de la electrofisiología". *Acta Ortopédica Mexicana*, 294-296.
- Galindo, C. (2011). Diseño y Evaluación de Prototipo de Mano Robot Controlada por Impulsos Mioeléctricos.
- García, E. Q., Darghan, A. E., & Fischer, G. (2017). Clasificación de variables morfológicas del duraznero (*Prunus persica* L. Batsch) 'Jarillo' en la montaña santandereana Colombiana mediante análisis discriminante lineal. *REVISTA COLOMBIANA DE CIENCIAS HORTÍCOLAS*, 39-47.
- Gila, L. M. (2009). Métodos de procesamiento y análisis de señales electromiográficas. . *An. Sist. Sanit. Navar.*, 27-43.
- Gilat, A. (2006). *Matlab: Una introducción con ejemplos prácticos*. Barcelona España: REVERTE.
- Giordano, L. S. (2018). Gestures classification from EMG signals. *In 2018 IEEE Biennial Congress of Argentina*, 1-6.
- Gómez, A. (2000). *Neuropatía y Miopatía*.
- González, J. M. (2005). Robótica y prótesis inteligentes. *Repositorio universitario de la DGTIC*, 1-15.
- Guevara, S. R. (2019). Diseño automático de un clasificador para filtrado de ruido en imágenes binarias utilizando análisis discriminante lineal. *Revista digital del Departamento de Ingeniería e Investigaciones Tecnológicas de la universidad Nacional de La matanza*, 1-9.
- Harold A. Romo, E. J. (2007). Análisis de Señales EMG Superficiales y su. *Revista Avances en Sistemas e Informática*, 126-136.

- Irving Aarón Cifuentes González, N. S. (2014). Metodología y diseño para la construcción de electrodos concéntricos para electromiografía. *Pistas Educativas*, 839-855.
- J. M. Weiss, L. D. (2015). *Easy EMG: A Guide to Performing Nerve Conduction Studies and Electromyography*. Elsevier Health Sciences.
- Jaque-Almendras, C. E.-F.-R.-P.-E. (2019). Neuropatía ciática en niños: presentación clínica y seguimiento a largo plazo. *Revista Chilena de Pediatría*, 91.
- Julian M. Fernandez. (2007). INFLUENCIA DE LA FATIGA MUSCULAR EN LA SEÑAL ELECTROMIOGRÁFICA DE MÚSCULOS ESTIMULADOS ELÉCTRICAMENTE. *Revista EIA*, 111-119.
- Larraz, E. L. (2009). Diseño de un sistema de reconocimiento del habla mediante. *Actas del XXVII Congreso Anual de la Sociedad Española de Ingeniería Biomédica*.
- Liu, E. A. (2018). Modelo de reconocimiento en tiempo real para gestos de la mano utilizando técnicas de deep learning y señales electromiográficas. *Escuela politécnico Nacional*, tesis.
- Loja, J.(2016). diseño y construcción de un exoesqueleto de rodilla robótica para asistir a pacientes en etapas de rehabilitación. *Licenciatura tesis, Universidad de Cuenca*.
- Márquez, M. B. (2008). *Diseño e Implementación de un Sistema*. Puebla, México: ©INAOE 2008.
- MathWorks. (09 de febrero de 2020). *classification learner*. Obtenido de MathWorks-classification learner: <https://la.mathworks.com/help/stats/classificationlearner-app.html>
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y aplicaciones*. México: Universidad Tecnológica Nacional.
- Mejia-Gonzalez, E. A.-L.-L.-C. (2019). Optimized Algorithm for Muscular Diseases Recognition Based On Temporal Parameters Analysis and Correlation Coefficients. *In Journal of Physics: Conference Series*, volumen 1304.
- Mora, I. S. (2000). *Sistema muscular*. Departamento de Educación Física.
- Moreira, L. E. (2003). Prótesis Inteligentes para Extremidades Superiores Utilizando DSP. *CIIE 2003 IV Congreso Iberoamericano*.
- Osorio, L. A. (2007). Acondicionamiento de señales bioeléctricas. *Doctoral dissertation, Universidad Tecnológica de Pereira. Facultad de Ingenierías Eléctrica, Electrónica, Física y Ciencias de la Computación. Ingeniería Eléctrica*.
- P. A. Karthick, G. V. (2015). Analysis of surface emg signals under fatigue and non-fatigue conditions using-distribution based quadratic time frequency distribution, *J. Mech. Med. Biol.*, vol. 15, no. 2,
- Pinzón, J. V. (.2012). Brazo robótico controlado por electromiografía. *. scientia et technica*, 1(52), , 165-173.
- Pinzón, M. R. (2009). CARACTERIZACIÓN DE SEÑALES ELECTROMIOGRÁFICAS PARA LA DISCRIMINACIÓN DE SEIS MOVIMIENTOS DE LA MANO. *Scientia et Technica*, 278-285.
- Pospíchal, J. &. (2015). 70th anniversary of publication: Warren mcculloch & walter pitts-a logical calculus of the ideas immanent in nervous activity. In *Emergent Trends in Robotics and Intelligent Systems*. Springer, Cham, 1-10.
- RAE, R. A. (17 de Agosto de 2019). *Real Academia Española*. Obtenido de Real Academia Española: <https://dle.rae.es/?id=US6Q9JZ>
- Romero, M. A. (2011). Análisis cinemático e implementación de una mano robótica servo-articulada aplicable como prótesis. *Análisis cinemático e implementación de una mano robótica servo-articulada aplicable como prótesis*. México D.F.
- Romo, H. A. (2007). Análisis de señales EMG superficiales y su aplicación en control de prótesis de mano. *Revista avances en sistemas e informática*, 127-136.

- Rubio, S. V. (2014). Patrón electromiográfico como método de diagnóstico precoz de la Miopatía de UCI. *Patrón electromiográfico como método de diagnóstico precoz de la Miopatía de UCI*. Tesis doctoral.
- Ruiz, O. (2014). Análisis Cinemático y Dinámico de un Robot Bípedo de 12 GDL. *Tesis Maestría, Universidad*.
- RYMER, P. Z. (2004). MUAP Number Estimates in Surface EMG: Template-Matching. *Annals of Biomedical Engineering*, 1007-1015.
- Sandoval, I. A. (2018). SIGNAL PROCESSING EMG IN AN EMBEDDED SYSTEM FOR CONTROL NEURONAL OF A ROBOTIC ARM. *Revista Colombiana de Tecnologías de Avanzada*, 139-147.
- Vadursi, M. (2010). *Data acquisition*. croacia: IntechOpen.
- Venegas, D. (2016). Diseño, construcción y Control de un exoesqueleto robótico para rehabilitación del sistema motriz y de marcha. *Tesis maestría, Instituto*.

Anexo 1 Códigos desarrollados

Parte 1 Código utilizado para la clasificación de las condiciones médicas.

```

clear all
clc
%El primer paso es cargar a Matlab los datos descargados de Physionet. las 3
condiciones médicas.
% se carga una EMG en formato texto
A= load('emg_healthy.txt');
B = load('emg_myopathy.txt');
C = load('emg_neuropathy.txt');
%se divide la información obtenida de Physionet, para recuperar solo la
información importante y tener la misma cantidad de datos para cada condición.
emg=[A(2000:42860,1) A(2000:42860,2) ];
emg2=[B(2000:42860,1) B(2000:42860,2) ];
emg3=[C(2000:42860,1) C(2000:42860,2) ];
%Se crea una matriz en la cual se guardarán los segmentos resultantes de la
segmentación adyacente, para cada condición.
H=ones(25,2000);
M=ones(25,2000);
N=ones(25,2000);
cnt=2000;
%obtención de segmentos adyacentes y obtención de parámetros estadísticos de
cada segmento
%-----extracción de características-----
for i=1:20
    H(i,:)=emg(((cnt*i)-cnt)+1:cnt*i,2);
    M(i,:)=emg2(((cnt*i)-cnt)+1:cnt*i,2);
    N(i,:)=emg3(((cnt*i)-cnt)+1:cnt*i,2);

    mediaH(1,i)=mean(H(i,:));
    mediaM(1,i)=mean(M(i,:));
    mediaN(1,i)=mean(N(i,:));

    varianzaH(1,i) = var(H(i,:));
    varianzaM(1,i) = var(M(i,:));
    varianzaN(1,i) = var(N(i,:));

    KH(1,i) = kurtosis(H(i,:));
    KM(1,i) = kurtosis(M(i,:));
    KN(1,i) = kurtosis(N(i,:));

    sH(1,i) = skewness(H(i,:)); %oblicuidad
    sM(1,i) = skewness(M(i,:)); %oblicuidad
    sN(1,i) = skewness(N(i,:)); %oblicuidad

    q1H(1,i) = quantile (H(i,:),.25); %calcula los cuartiles
    q2H(1,i) = quantile (H(i,:),.50);
    q3H(1,i) = quantile (H(i,:),.75);
    rqH(1,i) =iqr (H(i,:)); %rango inter-cuartil

    q1M(1,i) = quantile (M(i,:),.25); %calcula los cuartiles
    q2M(1,i) = quantile (M(i,:),.50);
    q3M(1,i) = quantile (M(i,:),.75);
    rqM(1,i) =iqr (M(i,:)); %rango inter-cuartil

```

```

q1N(1,i) = quantile (N(i,:),.25);
q2N(1,i) = quantile (N(i,:),.50);
q3N(1,i) = quantile (N(i,:),.75);
  rqN(1,i) =iqr (N(i,:)); %rango inter-cuartil

per10H(1,i) = prctile(H(i,:),.15);
per20H(1,i) = prctile(H(i,:),.20);
per50H(1,i) = prctile(H(i,:),.50);
per70H(1,i) = prctile(H(i,:),.70);
per90H(1,i) = prctile(H(i,:),.90);
RMSH(1,i)=rms (H(i,:));

  per10M(1,i) = prctile(M(i,:),.15);
per20M(1,i) = prctile(M(i,:),.20);
per50M(1,i) = prctile(M(i,:),.50);
per70M(1,i) = prctile(M(i,:),.70);
per90M(1,i) = prctile(M(i,:),.90);
RMSM(1,i)= rms (M(i,:));

  per10N(1,i) = prctile(N(i,:),.15);
per20N(1,i) = prctile(N(i,:),.20);
per50N(1,i) = prctile(N(i,:),.50);
per70N(1,i) = prctile(N(i,:),.70);
per90N(1,i) = prctile(N(i,:),.90);
RMSN(1,i)=rms (N(i,:));
end

%---- se calcula la media de cada parámetro estadístico para el sujeto
saludable-----
mmediaH=mean(mediaH(1,:));
mRMSH=mean(RMSH);
mvarH=mean(varianzaH(1,:));
mKH=mean(KH);
msH=mean(sH);
mrqH=mean(rqH);
mq1H=mean(q1H);
mq2H=mean(q2H);
mq3H=mean(q3H);
mper10H=mean(per10H);
mper20H=mean(per20H);
mper50H=mean(per50H);
mper70H=mean(per70H);
mper90H=mean(per90H);

%---- cálculo de la media de cada parámetro estadístico para la condición
Miopatía -----
mmediaM=mean(mediaM(1,:));
mRMSM=mean(RMSM);
mvarM=mean(varianzaM(1,:));
mKM=mean(KM);
msM=mean(sM);
mrqM=mean(rqM);
mq1M=mean(q1M);
mq2M=mean(q2M);
mq3M=mean(q3M);
mper10M=mean(per10M);

```

```

mper20M=mean(per20M);
mper50M=mean(per50M);
mper70M=mean(per70M);
mper90M=mean(per90M);

%---- cálculo de la media de cada parámetro estadístico para la condición
Neuropatía
mmediaN=mean(mediaN(1,:));
mRMSN=mean(RMSN);
mvarN=mean(varianzaN(1,:));
mKN=mean(KN);
msN=mean(sN);
mrqN=mean(rqN);
mq1N=mean(q1N);
mq2N=mean(q2N);
mq3N=mean(q3N);
mper10N=mean(per10N);
mper20N=mean(per20N);
mper50N=mean(per50N);
mper70N=mean(per70N);
mper90N=mean(per90N);

%-----Creación del Vector de características con la media de cada parámetro
estadístico calculado para cada condición.

Normal=[mmediaH mRMSH mvarH mKH msH mrqH mq1H mq2H mq3H mper10H mper20H
mper50H mper70H mper90H];
Myopathy=[mmediaM mRMSM mvarM mKM msM mrqM mq1M mq2M mq3M mper10M mper20M
mper50M mper70M mper90M];
Neuropathy=[mmediaN mRMSN mvarN mKN msN mrqN mq1N mq2N mq3N mper10N
mper20N mper50N mper70N mper90N];
%obtencion de la señal de prueba
C = (round(rand(1)*2))+1;
prueba = (round(rand(1)*19))+1;
if C==1
    senalprueba = H(prueba,:);
elseif C==2;
    senalprueba = M(prueba,:);

else
    senalprueba = N(prueba,:);
end

%-----obtención de características de la señal prueba----
mediap=mean(senalprueba);
RMSp=rms(senalprueba);
varp = var(senalprueba);
Kp = kurtosis(senalprueba);
sp = skewness(senalprueba);
rqp = iqr(senalprueba);
q1p = quantile ((senalprueba),.25);
q2p = quantile ((senalprueba),.50);
q3p = quantile ((senalprueba),.75);
per10p= prctile((senalprueba),.15);
per20p= prctile((senalprueba),.20);
per50p= prctile((senalprueba),.50);
per70p= prctile((senalprueba),.70);
per90p= prctile((senalprueba),.90);

```

```

%-----Vector de características de la señal de prueba---
caracprueba=[mediap RMSp varp Kp sp rqp q1p q2p q3p per10p per20p per50p
per70p per90p];
signal=caracprueba;
resultado=zeros(3,14);
F=20; %tolerancia permitida al algoritmo
%Determinación de la pertenencia a cada clase con una tolerancia establecida.
Comprobación de pertenencia a la clase Saludable.
for i=1:14
    if (abs(signal(1,i)) >= (abs(Normal(1,i)*(1-F)))) & (abs(signal(1,i))
<= (abs(Normal(1,i)*(1+F))))
        %disp('Normal')
        sign1 = signal(1,i) / Normal(1,i);
        if sign1 > 0
            resultado(1,i)=1;
        else
            resultado(1,i)=0;
        end
    end
end
%Comprobación de pertenencia a la clase Miopatía.
for i=1:14
    if (abs(signal(1,i)) >= abs((Myopathy(1,i))*(1-F))) &
(abs(signal(1,i)) <= (abs(Myopathy(1,i)*(1+F))))
        %disp('Myopathy')
        sign1=signal(1,i)/Myopathy(1,i);
        if sign1 > 0
            resultado(2,i)=1;
        else
            resultado(2,i)=0;
        end
    end
end
%Comprobación de pertenencia a la clase Neuropatía.
for i=1:14
    if (abs(signal(1,i)) >=(abs(Neuropathy(1,i)*(1-F))) &
(abs(signal(1,i)) <= (abs(Neuropathy(1,i)*(1+F))))
        %disp('Neuropathy')
        sign1=signal(1,i)/Neuropathy(1,i);
        if sign1 > 0
            resultado(3,i) = 1;
        else
            resultado(3,i)=0;
        end
    end
end
resultado;
%obtención del desempeño del algoritmo para la clasificación
probNormal=100*((sum(resultado(1,:)))/14)
probMyopathy=100*((sum(resultado(2,:)))/14)
probNeuropathy=100*((sum(resultado(3,:)))/14)

```

Parte 2 Algoritmo utilizado para la extracción de características de la EMGs del Vasto intermedio

```

%%se cargan los datos obtenidos con Myo Ware y pre-procesados en Arduino
uno%%
clc;
clear all;
caminar = xlsread('MYO2.xlsx','caminarcortado');
correr = xlsread('MYO2.xlsx','corrercortado');
SE = xlsread('MYO2.xlsx','secortado');
BE = xlsread('MYO2.xlsx','BECORTADO');
%%extracción de características CAMINAR%%
for i=1:10
    mediaCa(:,i) = mean(caminar(:,i));
    varCa(:,i) = var(caminar(:,i));
    KHCa(:,i) = kurtosis(caminar(:,i));
    SCa(:,i) = skewness(caminar(:,i)); %oblicuidad
    q1Ca(:,i) = quantile (caminar(:,i),.25); %calcula los cuartiles
    q2Ca(:,i) = quantile (caminar(:,i),.50); %calcula los cuartiles
    q3Ca(:,i) = quantile (caminar(:,i),.75); %calcula los cuartiles
    rqCa(:,i) = iqr (caminar(:,i)); %rango inter-cuartil
    per10Ca(:,i) = prctile(caminar(:,i),.15);
    per20Ca(:,i) = prctile(caminar(:,i),.20);
    per50Ca(:,i) = prctile(caminar(:,i),.50);
    per70Ca(:,i) = prctile(caminar(:,i),.70);
    per90Ca(:,i) = prctile(caminar(:,i),.90);
    RMSCa(:,i) = rms(caminar(:,i));
    DESCa(:,i)=std (caminar(:,i));
    MECa(:,i)= median(caminar(:,i));
    MaxCa(:,i)=max(caminar(:,i));
    ModaCa(:,i)=mode(caminar(:,i));
    RangoCa(:,i)= (max(caminar(:,i)) - min(caminar(:,i)));
    MinCa(:,i)=min(caminar(:,i));
end

%%extracción de características CORRER%%
for i=1:10
    mediaCo(:,i) = mean(correr(:,i));
    varCo(:,i) = var(correr(:,i));
    KHCo(:,i) = kurtosis(correr(:,i));
    SCo(:,i) = skewness(correr(:,i)); %oblicuidad
    q1Co(:,i) = quantile (corrер(:,i),.25); %calcula los cuartiles
    q2Co(:,i) = quantile (corrер(:,i),.50); %calcula los cuartiles
    q3Co(:,i) = quantile (corrер(:,i),.75); %calcula los cuartiles
    rqCo(:,i) = iqr (corrер(:,i)); %rango inter-cuartil
    per10Co(:,i) = prctile(corrер(:,i),.15);
    per20Co(:,i) = prctile(corrер(:,i),.20);
    per50Co(:,i) = prctile(corrер(:,i),.50);
    per70Co(:,i) = prctile(corrер(:,i),.70);
    per90Co(:,i) = prctile(corrер(:,i),.90);
    RMSCo(:,i) = rms(corrер(:,i));
    DESCo(:,i)=std (corrер(:,i));
    MECo(:,i)= median(corrер(:,i));
    MaxCo(:,i)=max(corrер(:,i));
    MinCo(:,i)=min(corrер(:,i));
    ModaCo(:,i)=mode(corrер(:,i));
    RangoCo(:,i)= (max(corrер(:,i)) - min(corrер(:,i)));

```

end

%%extracción de características SUBIR ESCALERAS%%

for i=1:10

```

mediaSE(:,i) = mean(SE(:,i));
varSE(:,i) = var(SE(:,i));
KHSE(:,i) = kurtosis(SE(:,i));
SSE(:,i) = skewness(SE(:,i)); %oblicuidad
q1SE(:,i) = quantile (SE(:,i),.25);
q2SE(:,i) = quantile (SE(:,i),.50);
q3SE(:,i) = quantile (SE(:,i),.75);
rqSE(:,i) = iqr (SE(:,i)); %rango inter-cuartil
per10SE(:,i) = prctile(SE(:,i),.15);
per20SE(:,i) = prctile(SE(:,i),.20);
per50SE(:,i) = prctile(SE(:,i),.50);
per70SE(:,i) = prctile(SE(:,i),.70);
per90SE(:,i) = prctile(SE(:,i),.90);
RMSSE(:,i) = rms(SE(:,i));
DESSE(:,i)=std (SE(:,i));
MESE(:,i)= median(SE(:,i));
MaxSE(:,i)=max(SE(:,i));
ModaSE(:,i)=mode(SE(:,i));
MinSE(:,i)=min(SE(:,i));
RangoSE(:,i)= (max(SE(:,i)) - min(SE(:,i)));

```

end

%%extracción de características BAJAR ESCALERAS%%

for i=1:10

```

mediaBE(:,i) = mean(BE(:,i));
varBE(:,i) = var(BE(:,i));
KHBE(:,i) = kurtosis(BE(:,i));
SSBE(:,i) = skewness(BE(:,i)); %oblicuidad
q1BE(:,i) = quantile (BE(:,i),.25); %calcula los cuartiles
q2BE(:,i) = quantile (BE(:,i),.50);
q3BE(:,i) = quantile (BE(:,i),.75);
rqBE(:,i) = iqr (BE(:,i)); %rango inter-cuartil
per10BE(:,i) = prctile(BE(:,i),.15);
per20BE(:,i) = prctile(BE(:,i),.20);
per50BE(:,i) = prctile(BE(:,i),.50);
per70BE(:,i) = prctile(BE(:,i),.70);
per90BE(:,i) = prctile(BE(:,i),.90);
RMSBE(:,i) = rms(BE(:,i));
DESBE(:,i)= std(BE(:,i));
MEBE(:,i)= median(BE(:,i));
MaxBE(:,i)=max(BE(:,i));
MinBE(:,i)=min(BE(:,i));
ModaBE(:,i)=mode(BE(:,i));
RangoBE(:,i)= (max(BE(:,i)) - min(BE(:,i)));

```

end

%%Creación de los vectores de características%%

```

VcCaminar=[mediaCa varC KHcA KHcA SSCa q1Ca q2Ca q3Ca rqCa per10Ca per20Ca
per50Ca per70Ca per90Ca RMSCa DESCa MECa MaxCa MinCa ModaCa RangoCa];
VcCorrer=[mediaCo varC KHCo KHCo SSCo q1Co q2Co q3Co rqCo per10Co per20Co
per50Co per70Co per90Co RMSCo DESCo MECo MaxCo MinCo ModaCo RangoCo];
VcSE=[mediaSE varSE KHSE KHSE SSSE q1SE q2SE q3SE rqSE per10SE per20SE per50SE
per70SE per90SE RMSSE DESE MESE MaxSE MinSE ModaSE RangoSE];
VcBE=[mediaSBE varBE KHBE KHBE SSBE q1BE q2BE q3BE rqBE per10BE per20BE
per50BE per70BE per90BE RMSBE DEBE MEBE MaxBE MinBE ModaBE RangoBE];
%Estos Vectores de características son la entrada para la app Classification
Learner de utilizada en Matlab.

```

Anexo 2. Problemática

2.1 Claridad del problema que resuelve

La paraplejía es una enfermedad que afecta a más de 20 millones de personas en el mundo, donde dichas personas presentan la capacidad nula de movilidad en sus piernas. Las personas que cuentan con la enfermedad paraplejía poseen distintas posibilidades de desenvolverse en el mundo de hoy en día, tal es el caso de las sillas de ruedas u ortesis, pero con la utilización de dichos aparatos las actividades a realizar son algo limitadas, por lo que se opta por elegir otros sistemas de movilidad, tal es el caso de los exoesqueletos electrónicos. Un exoesqueleto o exoesqueleto electrónico es un sistema mecatrónico con actuadores y sensores que son manejados por una unidad de control. La función principal de un exoesqueleto de miembros inferiores es brindar fuerza o devolver la movilidad a personas que por alguna razón hayan perdido la posibilidad de mover los miembros inferiores. Los dispositivos que existen actualmente, aunque tienen un gran avance tecnológico, aún están en proceso de desarrollo, su puesta en marcha en el mercado mundial apenas comienza, principalmente por el costo de los sistemas y la investigación misma dada la novedad del contexto. Entre algunas limitantes se encuentran, la dificultad en la generación de los modelos dinámicos con diferentes grados de libertad, el auto-equilibrio, los materiales, la durabilidad de las baterías, la ergonomía, el alto costo. Dichas limitantes dificultan la adquisición por parte de los usuarios de exoesqueletos. Cabe señalar que el procesamiento de la información está inmerso en estos exoesqueletos o prótesis activas. Una correcta clasificación de señales con parámetros temporales reduce costos y tiempo de procesado, manteniendo la eficiencia de los sistemas permitiendo desarrollar prótesis y exoesqueletos de bajo costo.

2.2 Empresas potenciales en la localidad que podrían beneficiarse con la implementación del algoritmo:

El algoritmo desarrollado no solo está enfocado a la implementación en prótesis activas. También va dirigida aquellas tareas que necesite realizar una clasificación de señales. En este sentido los beneficiarios potenciales son las universidades, centros de investigación y centros médicos que desarrollen prótesis, enseguida se enlistan algunas universidades y dentro de desarrollo de prótesis en Ensenada

- Centro de Investigación Científica y de Educación Superior de Ensenada, Baja California.
- REHABILITA Center "Centro de Fisioterapia y Electromiografía" Ensenada B.C.
- Hospital VELMAR
- Universidad Autónoma de Baja California (UABC)
- CNYN-UNAM, Km 107 Carretera Tijuana-Ensenada. Ensenada, Baja California

3.2 Código Arduino para la obtención de la EMGs

/ La rutina inicia al presionar el botón de reset

```
void setup() {
```

// Se inicia la comunicación serial a 9600 bits por segundo

```
Serial.begin(9600);
```

```
}
```

// La rutina en el ciclo correrá indefinidamente

```
void loop() {
```

// Lectura del sensor Myo ware en el pin 0:

```
int sensorValue = analogRead(A0);
```

// Conversión de la altura analógica (la cual va de 0 - 1023) voltaje (0 - 5V):

```
float voltage = sensorValue * (5.0 / 1023.0);
```

// Muestra en pantalla la lectura realizada

```
Serial.println(voltage);
```

```
delay(1); % tiempo de espera entre lectura (1 milisegundo)
```

```
}
```

3.3 Guía para la colocación de electrodos en el músculo Vasto intermedio, para la lectura de la flexo-extensión de la rodilla.

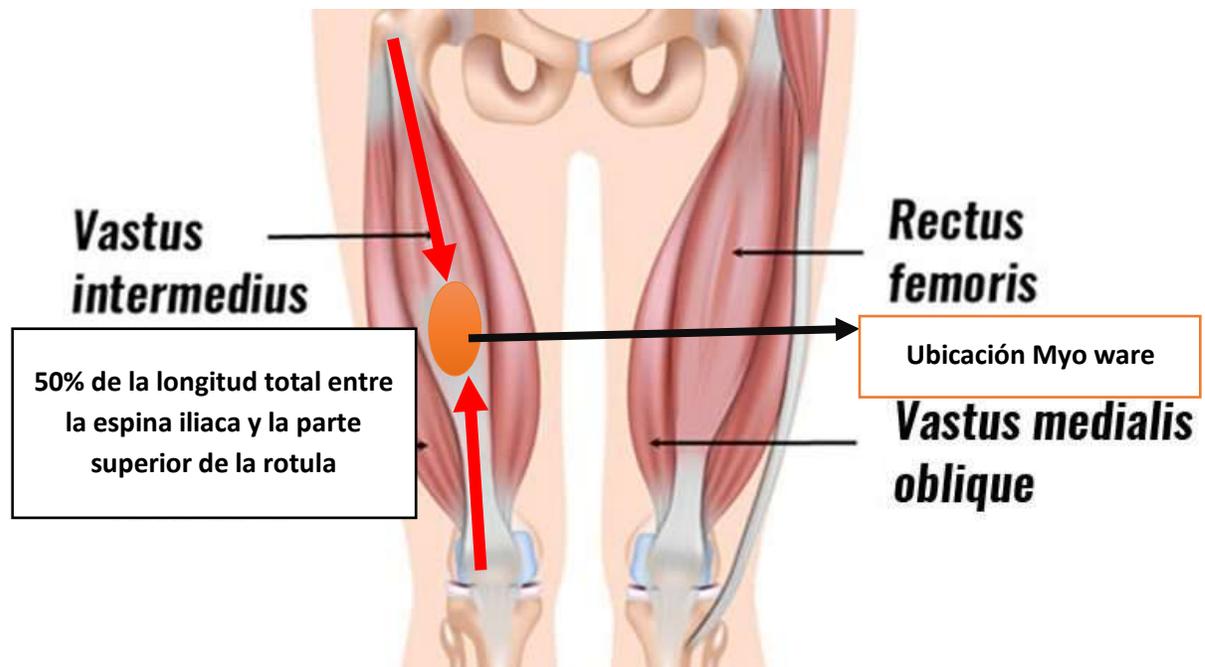


Figura 33 Posición Myo ware para el registro de EMGs en el muslo Vasto intermedio.

Anexo 4. Análisis de Pertinencia del proyecto

En el contexto de prótesis activas y exoesqueletos comerciales algunos de las más importantes son: Aupa, JACE S600, JACE S603, Armeo® Spring, Armeo® Spring Pediatric, Armeo® Boom, Armeo® Power. Entre sus principales desventajas de estos dispositivos son: las medidas antropométricas en las cuales se basa su diseño, no corresponden a las de la población mexicana y su alto costo de adquisición y de mantenimiento los hacen inaccesibles para la mayoría de la población mexicana. Los principales problemas que se presentan al desarrollar un dispositivo para rehabilitación son: determinar los movimientos en base al estímulo generado y definir el diseño mecánico apropiado para las tareas de movimiento que realiza el paciente, ya que la prescripción de éstas y la entrada mecánica restringen el diseño y el control mecánico del dispositivo robótico de terapia. (Méndez, González, & M, 2017). Es necesario impulsar en México la investigación dirigida al desarrollo e integración completa de un sistema protésico global que sea económico y eficiente, teniendo en cuenta las consideraciones fisiológicas de la población mexicana.

Anexo 5. Análisis de Viabilidad de éxito.

5.1 Análisis FODA

Fortalezas	Debilidades
<ul style="list-style-type: none"> • En México hacen falta empresas que comercialicen y fabriquen prótesis y exoesqueletos <ul style="list-style-type: none"> • Existe una gran cantidad de profesionistas que no cuentan con proyectos para desarrollar sus habilidades. • El desarrollo de un exoesqueleto con insumos económicos se traduce en el desarrollo de un producto de bajo costo • Interés nacional: siendo un proyecto que apunta a mejorar la calidad de vida de las personas, generar empleo y desarrollar la industria tecnológica nacional, se obtendrá apoyo de sectores clave, entre ellos el gubernamental 	<ul style="list-style-type: none"> • La curva de aprendizaje debido al contexto puede ser de largo tiempo • Al ser una empresa nueva al inicio de operaciones puede resultar en una baja demanda en volumen
Oportunidades	Amenasas
<ul style="list-style-type: none"> • Existe una demanda insatisfecha debido a los altos costos y mantenimiento de los equipos existentes • Actualmente los equipos disponibles son de procedencia extranjera y generalmente no se ajustan a la población mexicana 	<ul style="list-style-type: none"> • Las regulaciones mexicanas, debido al contexto de innovación no están actualizadas y pueden llegar a existir problemas regulatorios • La investigación en prótesis y desarrollo de equipos actualmente está en auge y esto puede llevar a la creciente creación de empresas con mayor presupuesto.

Figura 34 Análisis Foda

5.2 Análisis Canvas

5.2.1 Propuesta de valor

La clasificación de señales EMGs obtenidas basada en parámetros temporales reduce tiempo de procesamiento, reduce capacidades de cómputo, lo cual está directamente relacionado con un ahorro en la incorporación de procesadores para el desarrollo de prótesis activas

5.2.2 Relaciones con los clientes

La forma más viable de acceder a clientes es creando convenios con hospitales centros de rehabilitación, médicos, fundaciones de ayuda social. Establecer canales de comunicación para brindar atención sobre dudas, mantenimiento, costos de los productos

5.2.3 Segmentos de mercado

La población mexicana a grandes rasgos puede dividirse en 3 clases sociales, la clase alta, media y baja. El desarrollo de una empresa destinada a la venta de prótesis activas estará enfocada a la clase media y baja, que representa una enorme ventaja competitiva debido a que los dispositivos que actualmente existen tienen precios muy altos, prácticamente inaccesible para la población de clase media-baja.

5.2.4 Actividades claves

Las opciones actuales para la población mexicana para adquirir una prótesis activa tienen muchas dificultades.

Por lo que las actividades claves en este proyecto comprenden:

- Servicio al cliente
- Atención personalizada
- Mejoras continuas del producto logística de la distribución

5.2.5 Recursos claves

- Impresora 3D
- CNC

- Personal especializado en ingeniería biomédica o afín
- Equipos de computo

5.2.6 Socios claves

- Universidades que apoyen a la investigación
- Centros de rehabilitación
- Hospitales

5.2.7 Estructura de costos

El proyecto estará enfocada a la creación de valor debido a la implementación de un producto de bajo costo con respecto a la competencia es necesaria una evolución como empresa e innovar continuamente sin descuidar el factor principal que es la calidad y el bajo costo.

Anexo 6. Impactos potenciales y esperados para el beneficiario.

Una Prótesis activa tiene la capacidad de reincorporar a los usuarios a sus vidas, mejorando sustancialmente la forma en la que se desenvuelven en la sociedad, y al mismo tiempo se mejora la parte psicología y social del usuario. Sumado a lo anterior, la calidad de vida de una persona parapléjica está destinada a una dependencia continua de las demás personas para una ayuda en el desplazamiento. El deseo de tener mayor movilidad e independencia que la brindada por la silla de ruedas ha encontrado una realización a través del desarrollo de exoesqueletos robóticos, los cuales son, básicamente, un dispositivo que es usado sobre el cuerpo humano a manera de prenda de vestir, que son mecánicamente compatibles con la anatomía humana, para permitir el movimiento seguro en el usuario y no obstruir u oponer resistencia al mismo. Estos dispositivos se usan alrededor de las piernas y espalda, el movimiento se obtiene gracias a motores eléctricos que mueven las piernas para brindar locomoción mientras que el balance se obtiene con muletas. Los exoesqueletos no sólo proporcionan la habilidad de locomoción a las personas con discapacidades sino también la oportunidad de sentirse sanas

Anexo 7 Administraciones del proyecto

7.1 Administración del alcance (Recolección de requisitos, Definición del alcance y Creación de la EDT).

Recolección de requisitos: Cabe señalar que, por la naturaleza del trabajo, los requisitos iniciales estuvieron cambiando, nutriéndose en cada revisión, o ajustándose, el trabajo se alimenta esencialmente de dos criterios, el criterio del asesor y el criterio del estudiante.

	DOCUMENTACIÓN DE REQUISITOS	<table border="1"> <tr> <td>No.</td> <td>1</td> </tr> <tr> <td>Revisión</td> <td></td> </tr> <tr> <td>fecha</td> <td></td> </tr> <tr> <td></td> <td></td> </tr> </table>	No.	1	Revisión		fecha			
	No.	1								
Revisión										
fecha										
INFORME AVANCE PROYECTO										

Categorización optimizada de señales Electromiográficas del Vasto intermedio relacionados con amputaciones transfemorales.	
<p style="text-align: center; color: red;">Requisitos del vector de características:</p> <div style="border: 1px solid black; padding: 5px; margin-top: 10px;"> <p>1) Media 2) Moda 3) Varianza 4) Oblicuidad 5) Cuartiles 6) Rango 7) Percentiles 8) Máximo 9) Mínimo 10) Rango inter-cuartil</p> </div>	<p style="text-align: center; color: red;">Características del clasificador</p> <div style="border: 1px solid black; padding: 5px; margin-top: 10px;"> <p>El clasificador debe utilizar solo parámetros temporales</p> <p>Las señales EMG deben adquirirse de acuerdo al estándar SENIAM</p> <p>El uso de los equipos debe apegarse a sus manuales</p> <p>El clasificador se realiza en Matlab</p> </div>
<div style="border: 1px solid black; padding: 5px; margin-top: 10px;"> <p style="text-align: center; color: red;">OBSERVACIONES</p> </div>	
<div style="border: 1px solid green; padding: 5px; margin-top: 10px;"> <p>Elaborado por: Efraín Mejía</p> </div>	<div style="border: 1px solid green; padding: 5px; margin-top: 10px;"> <p>Autorizado: Dr. Josué López</p> </div>

Figura 36 Documentación de requisitos

Definición del alcance:

EDT

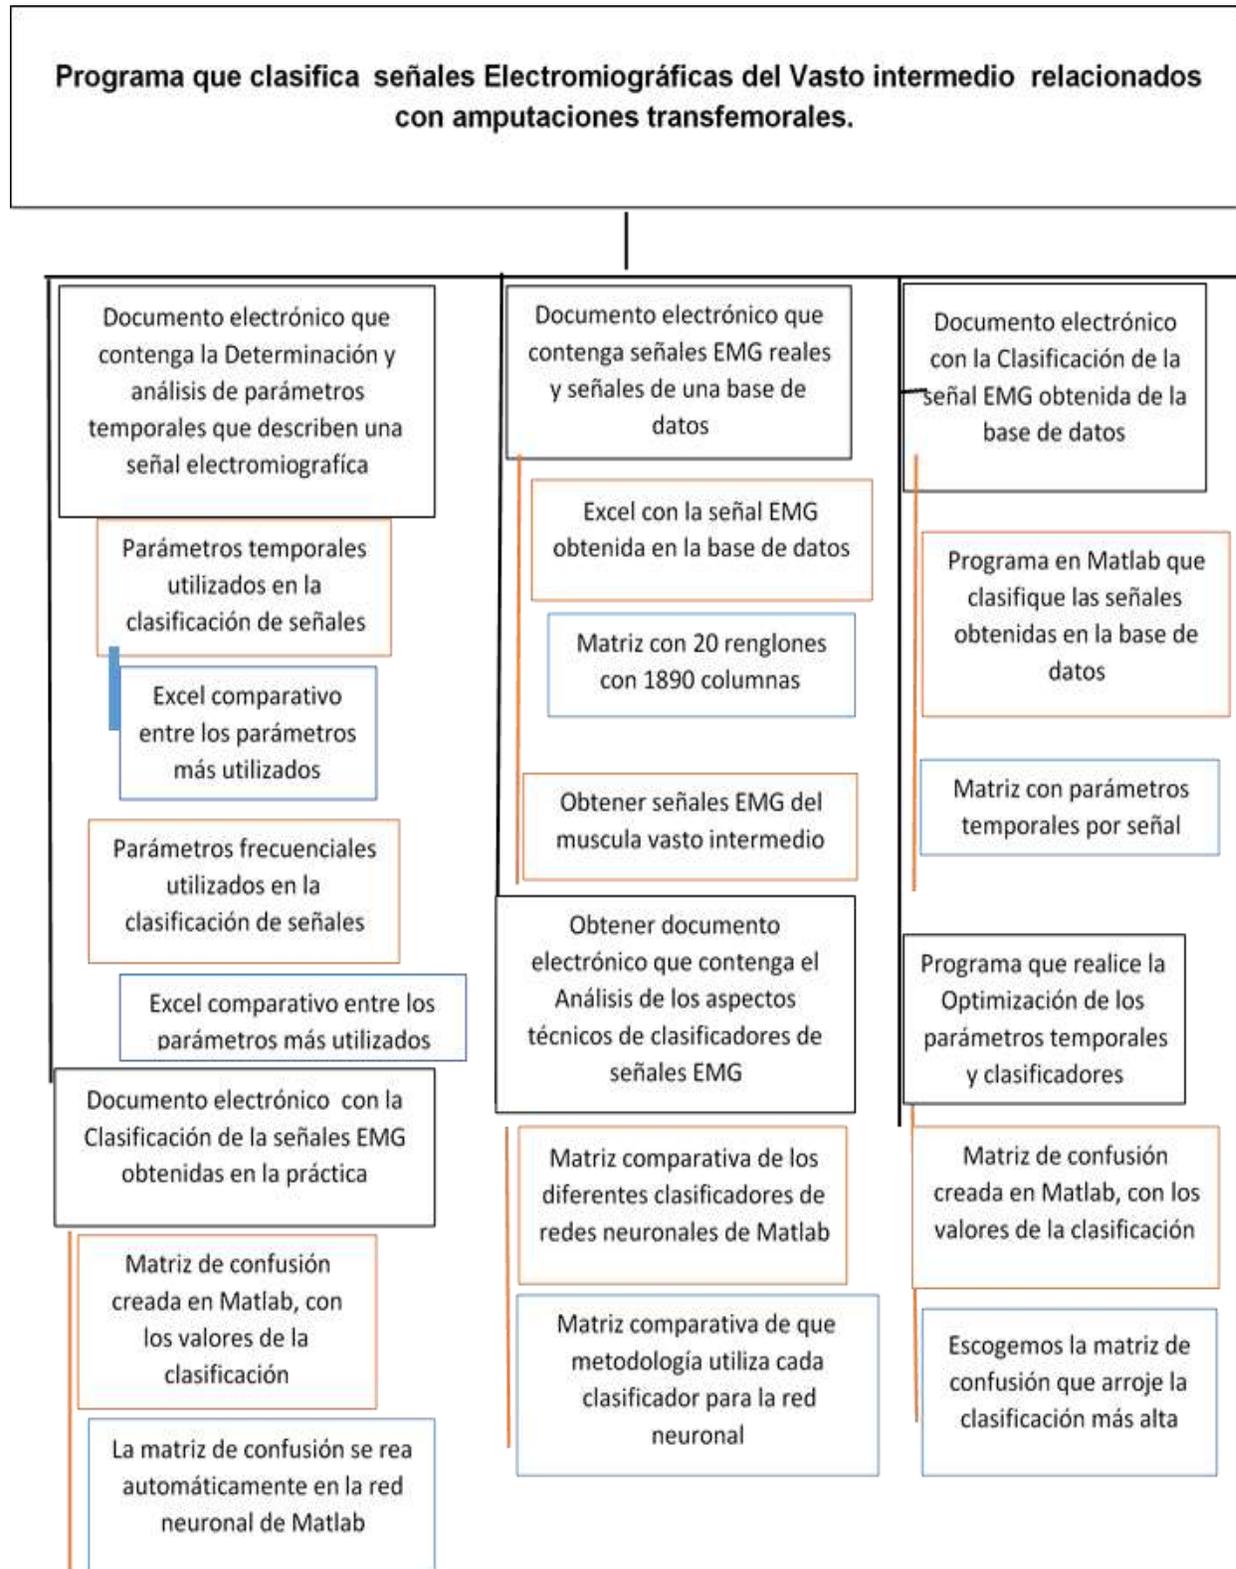


Figura 37 EDT

7.2 Administración del costo (Presupuesto y Flujo de efectivo)

Tabla 2 Administración del costo

instrumento	referencia	Lugar compra	precio	Fecha de compra
MyoWare Muscle Sensor	Hoja de datos	Mercado libre	100 dlls	Enero 2019
Cables (Jumpers)	N/A	Mercado libre	10 dlls (100 unidades)	Enero 2019
Arduino UNO	Hoja de datos	Mercado libre	10-15 dlls	Enero 2019
Electrodos 3M	Hoja de datos	Ciprés material médico. Ensenada B.C	30 dlls (Paquete 50 electrodos)	Enero 2019
Toma de señales EMG	Estándar SENIAM	N/A	N/A	N/A
Matlab	Publicaciones comparar resultados	N/A	10 dlls LICENCIA NORMAL	Enero 2019
Laptop	Hoja de datos	N/a	N/A	Al inicio del proyecto
			Total: 165 dólares	

Tabla 3 administración de la calidad

instrumento	referencia	revisión	autorizado
MyoWare Muscle Sensor	Hoja de datos	Advancer Technologies	Los avances son examinados semanalmente, según el formato de requisitos
Arduino	Hoja de datos	ARDUINO UNO	Los avances son examinados semanalmente, según el formato de requisitos
Electrodos 3M	Hoja de datos	3M™ Red Dot™ 2237, soporte de foam.	Los avances son examinados semanalmente, según el formato de requisitos
Toma de señales EMG	Estándar SENIAM	SENIAM	Los avances son examinados semanalmente, según el formato de requisitos
Matlab	Publicaciones comparar resultados	Publicaciones oficiales	Los avances son examinados semanalmente, según el formato de requisitos

Cada implementación, toma de mediciones, o resultados obtenidos, se examinan con el asesor, en las reuniones programadas.

Cabe señalar que los resultados obtenidos son siempre comparados con resultados de publicaciones en revistas arbitradas, o artículos indexados o arbitrados, con como máximo 5 años de antigüedad

Para el uso de los equipos, se da una breve descripción de su funcionamiento y sus indicadores a fin de administrar que estos sean verídicos:

MyoWare Muscle Sensor: Los valores obtenidos se comparan con los datos que provee el equipo, en su hoja de datos, los valores de salida están en el rango de 1 a 5 volts, las señales captadas, dependen en gran medida del correcto posicionamiento de los sensores (electrodos), cabe mencionar que los electrodos, se colocan de acuerdo al estándar SENIAM para el monitoreo del músculo especificado.

Arduino UNO: Información de la hoja de datos: <https://www.farnell.com/datasheets/1682209.pdf>

Electrodos 3M: La compra de los electrodos se realizó en un establecimiento que provee equipo grado médico. Garantizando la calidad del producto los electrodos están destinados al monitoreo de Electromiografías y electrocardiogramas.

Toma de señales EMG: La elección de los músculos de estudios, y el correcto posicionamiento de los electrodos, para la adquisición de las señales electromiográficas se lleva de acuerdo al estándar europeo SENIAM.

Matlab: Los resultados de las primeras clasificaciones, con parámetros temporales, se realiza con señales electromiográficas, de una base de datos, a manera de comparar resultados. La base de datos utilizada es: <https://physionet.org/content/emgdb/1.0.0/>

Los resultados obtenidos mediante las clasificaciones con parámetros temporales, como con los clasificadores de redes neuronales, con comparados con los resultados encontrados en publicaciones oficiales, a manera de crear una clasificación optimizada, en cuanto a los criterios previamente establecidos.

7.4 Administración de los recursos humanos (Plan de Recursos Humanos).

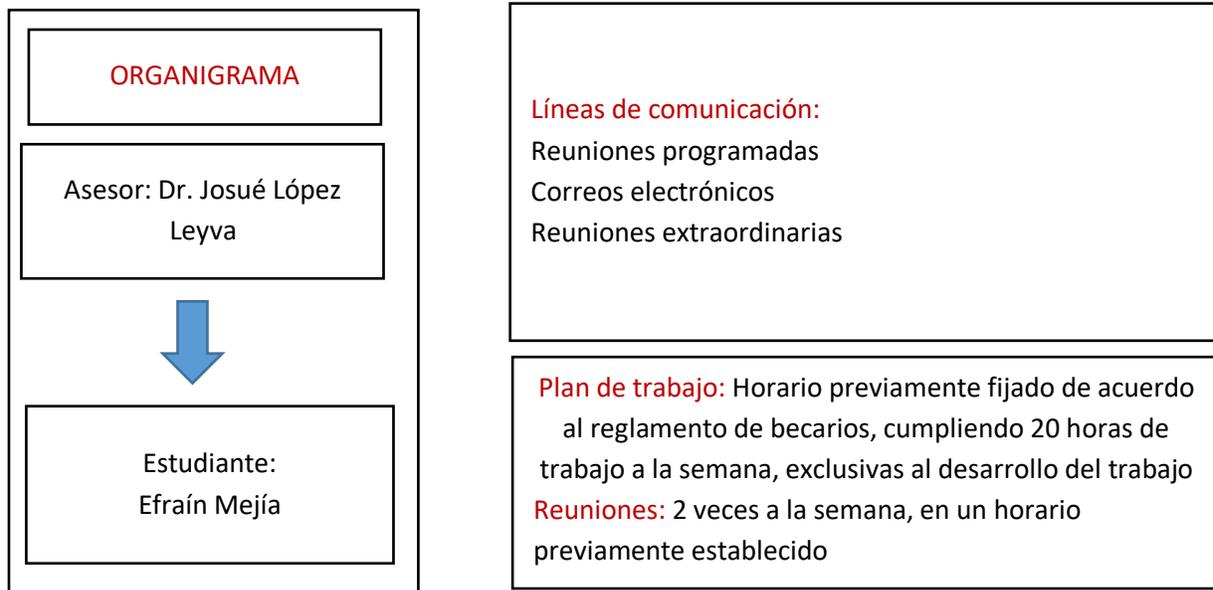


Figura 38 Administración recursos humanos

7.5 Administración de las comunicaciones (Plan de Comunicaciones).

Tabla 4 Administración de las comunicaciones

Horario	Lunes	martes	miércoles	jueves	viernes
12-13	Reunión oficina Dr. Josué				Reunión oficina Dr. Josué

La documentación de requisitos se llevará a una de las reuniones para hacer modificaciones, de acuerdo a criterios nuevos, y realizar ajustes

El horario se ajusta cada trimestre, para ajustar horario de trabajo del asesor y del estudiante.

7.6 Administración de los riesgos (Plan de Respuesta a los riesgos).

Los riesgos que este proyecto conlleva, se enlistan a continuación:

1. Que el sistema de medición no sea el adecuado
2. Que los parámetros seleccionados no puedan ser medidos en tiempo real
3. Que el sistema de medición falle por suministro de electricidad
4. Que falle el sistema de comunicación de la nube por bajo flujo de datos
5. que algún sensor, MYOWARE, Arduino, o la laptop del estudiante sufran algún incidente, se pierdan o fallen

Tabla 5 Tabla de riesgos

equipo	Impacto de riesgo	probabilidad	riesgo
Myo ware	30%	20%	bajo
Arduino	50%	30%	medio
Electrodos	30%	50%	Medio
Laptop	40%	50%	Medio
Matlab	30%	50%	medio

La ponderación del riesgo se determinó por el nivel de porcentaje, si existen un porcentaje entre 0% a 20% es de bajo riesgo, si es mayor a 20% pero menor a 50% se considera riesgo medio y arriba de 50% ya es de alto riesgo.

Acciones preventivas:

Si existe algún problema con el uso de algún equipo, y este falle, ya sea por mala implementación, deficiencia del equipo, o algún accidente, no se toman las medidas necesarias, si algún equipo falla, deberá adquirirse nuevamente, y el trabajo se pausará

7.7 Administración de las adquisiciones (Plan de Adquisiciones).

Tabla 6 Administración de las adquisiciones

instrumento	referencia	Lugar compra	precio	Fecha de compra
MyoWare Muscle Sensor	Hoja de datos	Mercado libre	100 dlls	Enero 2019
Cables (Jumpers)	N/A	Mercado libre	10 dlls (100 unidades)	Enero 2019
Arduino UNO	Hoja de datos	Mercado libre	10-15 dlls	Enero 2019
Electrodos 3M	Hoja de datos	Ciprés material médico. Ensenada B.C	30 dlls (Paquete 50 electrodos)	Enero 2019
Toma de señales EMG	Estándar SENIAM	N/A	N/A	N/A
Matlab	Publicaciones comparar resultados	N/A	10 dlls LICENCIA NORMAL	Enero 2019
Laptop	Hoja de datos	N/a	N/A	Al inicio del proyecto

7.8 Administración de la integración

En el siguiente Diagrama los recuadros en negro representan los entregables, para cumplir el trabajo, desglosados de manera general en sus tareas

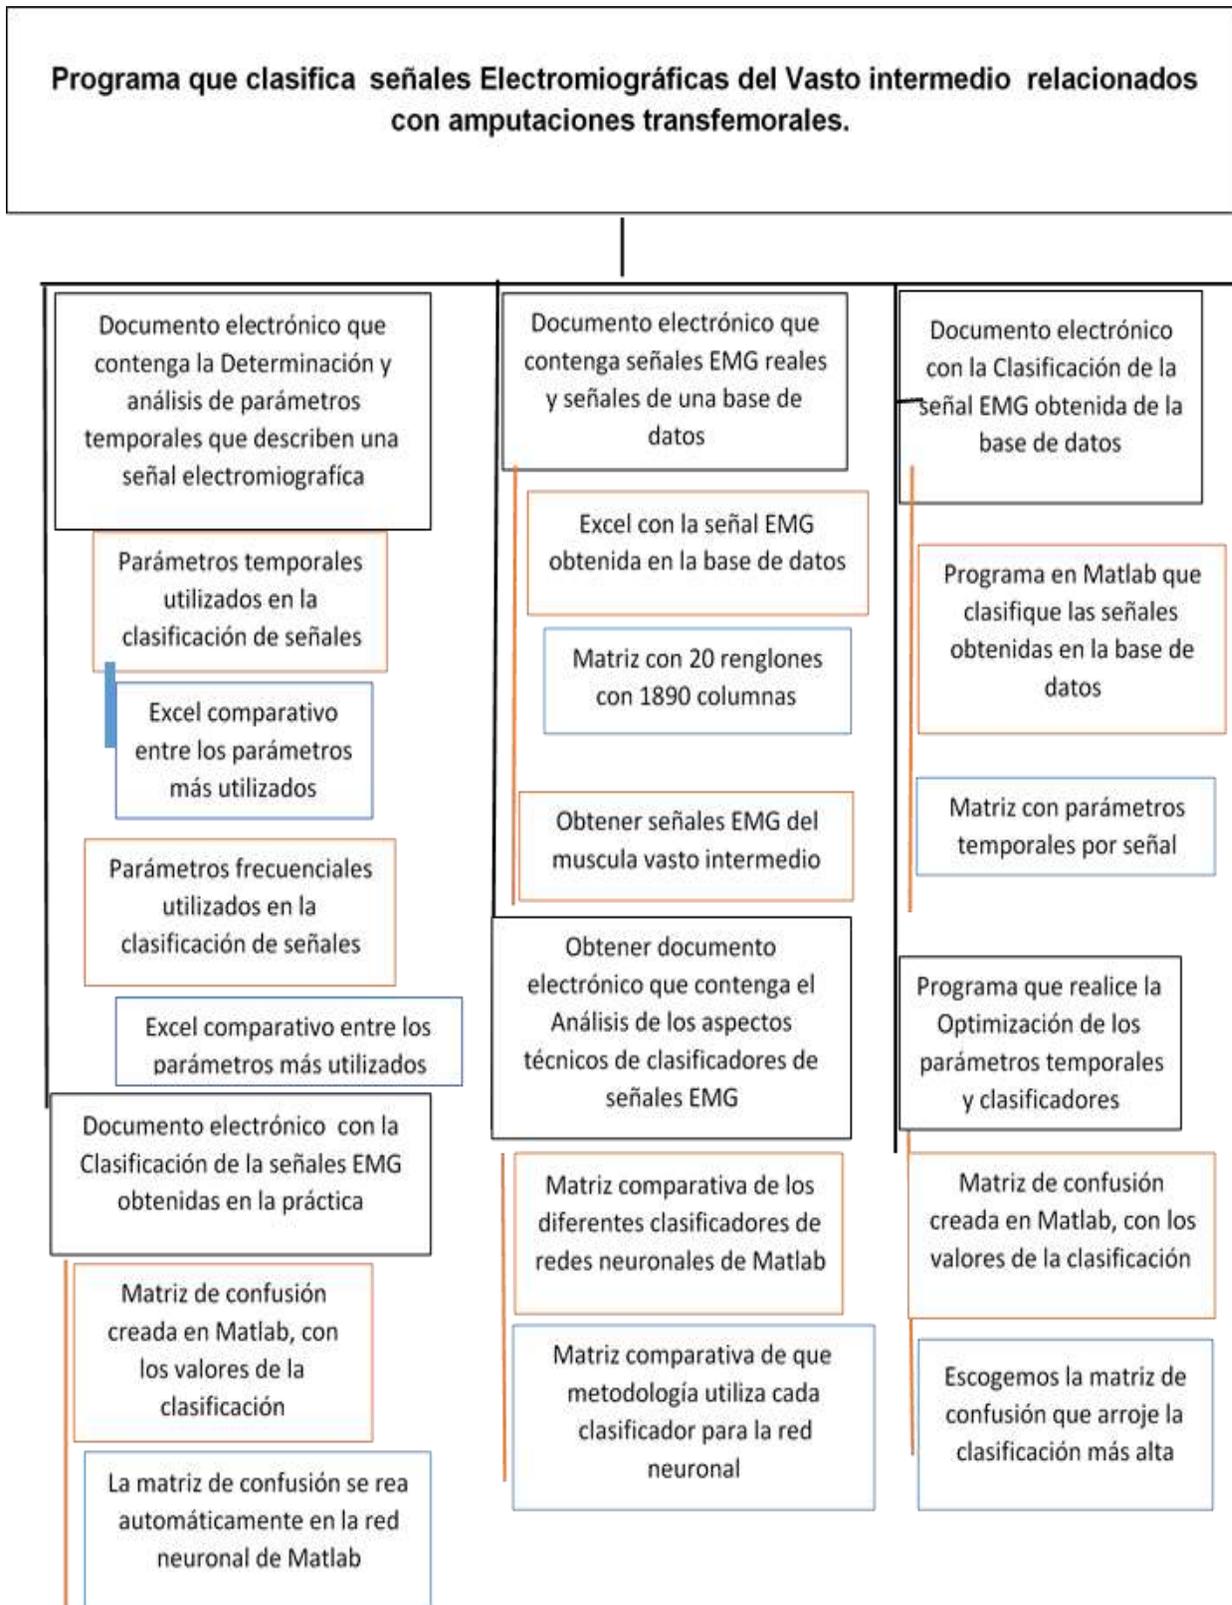


Figura 39 Administración de la integración

Tabla 7 Administración de los costos

instrumento	Referencia	Lugar compra	precio	Fecha de compra
MyoWare Muscle Sensor	Hoja de datos	Mercado libre	100 dlls	Enero 2019
Cables (Jumpers)	N/A	Mercado libre	10 dlls (100 unidades)	Enero 2019
Arduino UNO	Hoja de datos	Mercado libre	10-15 dlls	Enero 2019
Electrodos 3M	Hoja de datos	Ciprés material médico. Ensenada B.C	30 dlls (Paquete 50 electrodos)	Enero 2019
Toma de señales EMG	Estándar SENIAM	N/A	N/A	N/A
Matlab	Publicaciones comparar resultados	N/A	10 dlls LICENCIA NORMAL	Enero 2019
Laptop	Hoja de datos	N/a	N/A	Al inicio del proyecto
			Total: 165 dólares	

7.8 Evidencia de ejecución y control de proyecto.

Como evidencia de la ejecución los reglamentos del becario son claro, deberá por lo menos realizarse una publicación, aunque esta no sea aceptada, o alguna presentación en un congreso.

En mi caso particular, se ha ejecutado satisfactoriamente los trabajos, el trabajo se presentó en un congreso, y se publicó en una revista. Se anexa una captura de pantalla (figura 38) y el DOI del documento

doi:10.1088/1742-6596/1304/1/012020

Optimized Algorithm for Muscular Diseases Recognition Based On Temporal Parameters Analysis and Correlation Coefficients

E.A. Mejia-Gonzalez, J.A. Lopez-Leyva, J. Estrada-Lechuga and M.A. Ponce-Camacho

CETYS University, Centre of Innovation and design Ensenada, Baja California, Mexico

josue.lopez@cetys.mx

Abstract. In this paper, an optimized algorithm based on temporal parameters analysis and correlation coefficients is presented in order to perform muscular diseases recognition. Statistical information was measured of three classes signals (Healthy, Myopathy and Neuropathy conditions). The temporal parameters that were initially proposed (14) were optimized based on the correlation coefficients. Thus, only 9 parameters were selected for optimized the algorithm, and the time required for training and recognition is $\approx 0.2s$ and $\approx 4ms$, respectively.

Figura 40 evidencia cierre de proyecto

7.9 Evidencia de cierre de proyecto

Aunado al trabajo presentado, el cierre del proyecto y de la relación asesor-Becario, termina con la presentación de la tesis. Según lo estipulado en el reglamento para becarios de investigación.