


2021

Clasificación de señales mioeléctricas a partir
de SVMs para el accionamiento de una
prótesis transtibial

**Diana
Carolina
Toledo Pérez**



Universidad Autónoma de Querétaro
Facultad de Informática

Clasificación de señales mioeléctricas a partir de SVMs
para el accionamiento de una prótesis transtibial

TESIS

Que como parte de los requisitos para obtener el grado de
Doctorado en Ciencias de la Computación


Presenta:

M. en C. Diana Carolina Toledo Pérez

Dirigida por:

Dr. Juvenal Rodríguez Reséndiz

Querétaro, Qro. Marzo del 2021



Universidad Autónoma de Querétaro

Facultad de Informática

Doctorado en Ciencias de la Computación

Clasificación de señales mioeléctricas a partir de SVMs para el accionamiento de una prótesis transtibial

TESIS

Que como parte de los requisitos para obtener el grado de Doctora en Ciencias de la Computación

Presenta:

M. en C. Diana Carolina Toledo Pérez

Dirigida por:

Dr. Juvenal Rodríguez Reséndiz

Dr. Juvenal Rodríguez Reséndiz

Presidente

Dr. Roberto Augusto Gómez Loenzo

Secretario

Dr. Efrén Gorrostieta Hurtado

Vocal

Dr. José Emilio Vargas Soto

Suplente

Dr. Marco Antonio Aceves Fernández

Suplente

Centro Universitario, Querétaro, Qro.

Febrero, 2021

México

Dedicatorias

A mis padres, mis hermanos, mi esposo,
mis amigas que son como hermanas,
y en especial, a mi hija...
- *son mi motor de cada día*

Agradecimientos

Son muchas las personas que contribuyeron al desarrollo y conclusión de este proyecto. En primer lugar, me gustaría agradecer al Dr. Juvenal Rodríguez Reséndiz, director de esta tesis, quien me alentó a desarrollar esta investigación. En segundo lugar, quisiera agradecer al Dr. Miguel Ángel Martínez Prado, quien me ayudó con la parte electrónica del trabajo; indispensable para poder hacer mi base de datos; además me tuvo paciencia y me ayudó en todo lo que ocupé para terminar las tarjetas. En tercer lugar, a CONACYT, por financiar mis estudios de doctorado y la Universidad Autónoma de Querétaro, donde realicé dichos estudios.

Un agradecimiento especial a los compañeros y amistades que me regalaron un poco de su tiempo para formar la base de datos; ya que sin ellos no hubiera sido posible obtener los resultados de la experimentación. También quiero agradecer a aquellos que me ayudaron con sus ideas y a los que me escucharon cuando estaba frustrada cuando las cosas no salían.

Agradezco también a mis profesores, por haber compartido sus conocimientos conmigo; a mis padres Jorge y Deyssi, a mi hermano Julio y a mi esposo Eder por confiar y creer en mí; a mis amigas Nelly y Arely por escucharme cuando el trabajo me agobiaba; a mis ex – roomies Griz y Moni por asegurarse de que me ejercitara al acompañarme a mis partidos e ir conmigo a las retas; y asegurarse de que me distrajera y alimentara; al irnos al cine y a los tacos. Los amo a todos.

Índice general

1	Introducción	13
1.1	Descripción del problema	14
1.2	Justificación	15
2	Antecedentes	16
3	Hipótesis	24
4	Objetivos	24
4.1	Objetivo general	24
4.2	Objetivos particulares	24
5	Fundamentación teórica	25
5.1	Electromiografía	25
5.1.1	Sistema de adquisición	26
5.1.2	Algoritmos pre-procesados para clasificación	27
5.1.3	Decodificación de información mioeléctrica	27
5.2	Control mioeléctrico con base en reconocimiento de un patrón.....	28
5.2.1	Segmentación de datos	29
5.2.2	Extracción de características	30
5.3	Selección de características	32
5.3.1	Relief	32
5.3.2	SBMLR, Sparse Bayesian Multinomial Logistic Regression	33
5.4	Clasificación y control	34
5.4.1	Máquinas de Soporte de Vectores.....	34
5.4.2	Enfoque de redes neuronales.....	35
5.4.3	Enfoque de algoritmos difusos.....	35
5.4.4	Control mioeléctrico con base en reconocimiento sin patrón	36
5.5	Mecánica del pie	36
5.6	Prótesis de pie	38
5.7	Análisis de desempeño de un clasificador	38
5.7.1	Matrices de confusión	38
5.7.2	Especificidad	39

5.7.3	Sensibilidad.....	39
5.7.4	Exactitud	40
5.7.5	Precisión.....	40
6	Metodología.....	42
6.1	Tarjeta de adquisición de señales.....	43
6.2	Base de datos	49
6.3	Filtros.....	51
6.3.1	Filtro Notch.....	52
6.3.2	Filtro PasaBanda	53
6.4	Extracción de características.....	55
6.5	Selección de características	55
6.6	Análisis de Componentes Principales.....	57
6.7	Algoritmo de clasificación (SVMs).....	59
7	Resultados y discusión.....	60
7.1	Comparativa de canales	60
7.2	Selectiva de características	66
7.3	Selección del kernel.....	69
7.4	Validación del algoritmo	69
8	Conclusiones.....	91
9	Referencias.....	92

Índice de tablas

Tabla 2-1. Diseño general de una matriz de confusión.....	39
Tabla 4-1. Exactitud obtenida por sujeto con cada canal.....	61
Tabla 4-2. Exactitud obtenida por sujeto combinando dos canales, parte 1.	62
Tabla 4-3. Exactitud obtenida por sujeto combinando dos canales, parte 2.	63
Tabla 4-4. Exactitud obtenida por sujeto al combinar tres canales.....	64
Tabla 4-5. Exactitud obtenida por sujeto con cuatro canales.....	65
Tabla 4-6. Selección de características para cada sujeto con SMLR utilizando MAV, ZC, SSC y WL.	66
Tabla 4-7. Selección de características para cada sujeto con el algoritmo Relief utilizando MAV, ZC, SSC y WL.....	66
Tabla 4-8. Exactitud obtenida para cada sujeto.	67
Tabla 4-9. Exactitud obtenida para cada sujeto utilizando ZC, WL y SSC.....	68
Tabla 4-10. Exactitud obtenida con diferentes kernel.....	69
Tabla 4-11. Comparativa en exactitud con el trabajo de Sapsanis <i>et al.</i>	71
Tabla 4-12. Repeticiones utilizadas por experimento para Mujer 1.	71
Tabla 4-13. Repeticiones utilizadas por experimento para Mujer 2.	72
Tabla 4-14. Repeticiones utilizadas por experimento para Mujer 3.	72
Tabla 4-15. Repeticiones utilizadas por experimento para Mujer 4.	73
Tabla 4-16. Repeticiones utilizadas por experimento para Hombre 1.....	73
Tabla 4-17. Repeticiones utilizadas por experimento para Hombre 2.....	74
Tabla 4-18. Repeticiones utilizadas por experimento para Hombre 3.....	74
Tabla 4-19. Repeticiones utilizadas por experimento para Hombre 4.....	75
Tabla 4-20. Matriz de confusión de la prueba 1.....	76
Tabla 4-21. Matriz de confusión de la prueba 2.....	76
Tabla 4-22. Matriz de confusión de la prueba 3.....	77
Tabla 4-23. Matriz de confusión de la prueba 4.....	78
Tabla 4-24. Matriz de confusión de la prueba 5.....	79
Tabla 4-25. Matriz de confusión de la prueba 6.....	79
Tabla 4-26. Matriz de confusión de la prueba 7.....	80

Tabla 4-27. Matriz de confusión de la prueba 8.....	81
Tabla 4-28. Matriz de confusión de la prueba 9.....	81
Tabla 4-29. Matriz de confusión de la prueba 10.....	82
Tabla 4-30. Matriz de confusión promedio.....	83

Dirección General de Bibliotecas UAQ

Índice de figuras

Figura 1.1. Gráfica comparativa del desempeño de 7 clasificadores (Oskoei y Hu, 2008).	16
Figura 2.1. Diagrama esquemático de métodos de control de señales EMG (Hakonen <i>et al.</i> , 2015).	29
Figura 2.2. Articulación artrodiá (Barone <i>et al.</i> , 2012).	36
Figura 2.3. Palanca del pie. (A, punto de apoyo, R, punto de resistencia y P, punto de potencia) (Barone <i>et al.</i> , 2012).	37
Figura 2.4. Diferencia entre precisión y exactitud.	41
Figura 3.1. Diagrama general de tesis.	42
Figura 3.2. Adquisición de señal mioeléctrica.	44
Figura 3.3. Etapas de filtrado y doble amplificación de la señal.	45
Figura 3.4. Etapa de movimiento de referencia de la señal.	46
Figura 3.5. Electrodo Kendal MediTrace 200.	46
Figura 3.6. Cables para electrodos.	47
Figura 3.7. Tarjeta de adquisición de señales mioeléctricas.	48
Figura 3.8. Diagrama general del proceso de adquisición de señales.	51
Figura 3.9. Ceros y polos del filtro Notch.	52
Figura 3.10. Diagrama de frecuencias del filtro Notch.	53
Figura 3.11. Parámetros de diseño del filtro PasaBanda.	53
Figura 3.12. Muestra de una señal filtrada y una sin filtrar.	54
Figura 3.13. Diagrama a bloques del proceso de entrenamiento de la matriz de clasificación.	56
Figura 4.1. Descripción gráfica de los movimientos considerados.	70
Figura 4.2. Gráfica con estadísticas de sensibilidad, especificidad, exactitud y precisión promedio, obtenidas por cada movimiento.	84
Figura 4.3. Especificidad por movimiento.	85
Figura 4.4. Sensibilidad con líneas de tolerancia por movimiento.	85
Figura 4.5. Exactitud con líneas de tolerancia por movimiento.	86
Figura 4.6. Precisión con líneas de tolerancia por movimiento.	86
Figura 4.7. Gráfica de especificidad por prueba.	87
Figura 4.8. Gráfica de sensibilidad por prueba.	88

Figura 4.9. Gráfica de exactitud por prueba.....	89
Figura 4.10. Gráfica de precisión por prueba.....	90
Figura 4.11. Algoritmo propuesto para la clasificación de señales de EMG.....	91

Dirección General de Bibliotecas UAQ

Resumen en español

En este trabajo de investigación se realiza la clasificación de señales mioeléctricas, utilizando un algoritmo a través de máquinas de soporte vectorial. El objetivo de esta clasificación es que, en trabajos posteriores, el resultado de la clasificación se utilice en el accionamiento de prótesis que se encuentren debajo de la rodilla.

Para el desarrollo de la investigación se diseñaron y elaboraron tarjetas de adquisición de señales de electromiografía, las cuales envían las señales obtenidas a la PC. Con éstas se conformó una base de datos, con la cual se hicieron las pruebas de clasificación. Para el pretratamiento, las señales son filtradas y posteriormente se les hace una extracción de características, para formar el vector de entrada al algoritmo.

En una primera etapa, se realizó una comparativa de canales, con la finalidad de conocer si los cuatro canales utilizados son necesarios para obtener una mejor clasificación. Sin embargo, se encontró que uno de los músculos no tiene suficiente relevancia. Luego se analizaron diferentes algoritmos de selección de características, encontrando que el más efectivo es el *Relief*. Después se implementaron diferentes algoritmos de reducción de características, y se eligió implementar un análisis de componentes principales.

Más adelante, se realizaron comparaciones entre los resultados de la clasificación obtenidos con diferentes *kernels*, cuyos resultados arrojaron que el *kernel* lineal es el más útil al clasificar las señales de electromiografía obtenidas. Los parámetros usados para comparar el algoritmo fueron eficiencia, precisión, sensibilidad y especificidad. Para calcularlos se utilizaron matrices de confusión y se hicieron 10 diferentes pruebas.

En la etapa de validación se utilizó otra base de datos utilizada en la clasificación de otra publicación, probando que el algoritmo propuesto en este trabajo de investigación es mejor. Se mejoró la clasificación desde un 2.75% hasta un 6.95%.

Con las 10 pruebas realizadas al algoritmo propuesto, la especificidad promedio fue del 98%, la sensibilidad del 88%, la exactitud del 96.6% y la precisión del 87.9%.

Abstract

In this research work is realized myoelectric signals classification, using an algorithm through Support Vector Machine. Then, in later works, the results of this research can be used to drive prostheses, particularly those that are below the knee.

Electromyography signal acquisition cards were designed and developed to work out the research, which send the obtained signals to the PC. These signals make up the database with which the classification tests were made. To pretreatment, signals are filtered; later, feature extraction was made to form the input vector to the algorithm.

In the first stage, a comparison of channels was carried out in order to know if the four channels used are necessary to get a better classification. However, one of the muscles was found to have low relevance. Then, different feature selection algorithms were analyzed. Relief was the most effective. Afterward, reduction features algorithms were tested, and the Principal Component Analysis was chosen.

Subsequently, comparisons between different kernels were achieved. Kernel lineal is the most useful to classify the obtained myoelectric signals. The parameters used to compare the algorithm were efficiency, precision, sensibility, and specificity. To get them, confusion matrices were utilized, and they were made ten different tests.

In the validation stage, a different database from other research was used. And the result proved that the proposed algorithm in this research work is better. The classification was improved from 2.75% to 6.95%.

With the ten tests performed on the proposed algorithm, the average specificity was 98%, the sensitivity was 88%, the accuracy was 96.6%, and the precision was 87.9%.

1 Introducción

En los últimos años se han realizado grandes avances científicos y tecnológicos en la medicina; algunas de estas investigaciones se hacen en busca de una mejor calidad de vida para las personas con alguna clase de discapacidad. En lo que respecta las personas con amputaciones, en específico de la sección transtibial de la pierna (sección que comprende al pie y una parte entre la rodilla y el tobillo), se busca lograr las prótesis diseñadas para suplir esa parte del cuerpo, sean capaces de reproducir la marcha del ser humano lo más natural posible; que sea lo más comfortable y que no represente un gran gasto energético extra, tanto de la prótesis como del paciente en el momento de usarla.

En México, cada año se realizan una gran cantidad de amputaciones de extremidades, la mayoría como consecuencia del pie diabético. De las personas con pie diabético (complicación más común asociada a la diabetes mellitus), según la Asociación Latinoamericana de Diabetes, en México se reporta aproximadamente un 14% con egreso hospitalario después de una amputación (Arredondo y De Icaza, 2011), con un costo superior a 30 000 USD cada una de las amputaciones (Boulton *et al.*, 2008). La Encuesta Nacional de Salud y Nutrición del 2012, reportó que aproximadamente 128 mil individuos con diagnóstico de pie diabético sufrió una amputación (Rogers y Bevilacqua, 2010). En el año 2013, los sujetos amputados con pie diabético adscritos a Medicina Familiar en México fueron 3774, comparada con la cifra en 2004 de 2356 (Cisneros-González *et al.*, 2016).

Para el accionamiento de las prótesis existen varios métodos, entre los más novedosos se encuentra el uso de señales de electromiografía (EMG) (Parker y Scott, 1986; Asghari Oskoei y Hu, 2007); para las prótesis transtibiales normalmente se utilizan señales provenientes de los músculos de la pierna en la parte superior. Para poder clasificar estas señales y así accionar el dispositivo de control de la prótesis se utilizan algoritmos de reconocimiento de patrones, tales como las máquinas de soporte de vectores (SVMs, por sus siglas en inglés, Support Vector Machines), redes neuronales artificiales y análisis discriminante lineal (Oskoei y Hu, 2008; Geethanjali, 2016; Dhindsa *et al.*, 2019); sin

embargo las SVMs han probado ser uno de los mejores métodos en aplicaciones médicas (Kalantari *et al.*, 2018).

En este trabajo de investigación se describe la forma en cómo se diseñó un algoritmo basado en SVMs, el cual clasifica señales electromiográficas y presenta una exactitud más alta que otros algoritmos de clasificación, con un costo computacional suficientemente pequeño para que la clasificación se haga en “tiempo real”, lo que en este contexto se refiere a que el tiempo de respuesta es menor al de la reacción del cuerpo humano. Además de SVMs, la propuesta utiliza algoritmos de reducción de características y otros de selección; para así reducir el tiempo de procesamiento.

1.1 Descripción del problema

Las propiedades no estacionarias de las señales mioeléctricas en ajustes de la vida real obstaculizan las aplicaciones clínicas del reconocimiento de patrones mioeléctricas para control de prótesis, ya que modifican sus características a través del tiempo. Además, el hecho de que se tenga un número limitado de patrones, dificulta la movilidad de la prótesis, al no ajustarse al movimiento exacto que desea el usuario, lo que hace que la marcha no sea tan “natural”, obligando al usuario a modificar su manera de andar, lo que, a la larga, puede causar daños en la extremidad residual o en la sana, como señalan Russell-Esposito y Wilken (2014) que presentan un estudio enfocado a personas que utilizan prótesis transtibiales pasivas, es decir, que no tienen ningún dispositivo de control o accionamiento, presentan afectaciones en la extremidad sana, esta debido a que la carga aumenta y al tener que realizar compensaciones de empuje, lo que representa un mayor riesgo de daño en el cartílago de la rodilla (osteoartritis), por lo que las prótesis accionadas ofrecen más beneficios, al reducir las demandas de la extremidad sana.

Las prótesis accionadas o controladas, requieren de la distinción entre cada uno de los movimientos que pueden ejecutar (también llamados clases o patrones), los movimientos pueden ser indicados a través de señales de EMG; lo que representa un problema para los que las diseñan. Una de las soluciones dadas para éste es el desarrollo de algoritmos de reconocimiento de patrones. Sin embargo, una clasificación de una mayor cantidad de clases,

requiere de un alto costo computacional. Además, el incremento en el número de movimientos aumenta el error en la clasificación al tener un mayor número de patrones entre los cuales escoger, por estos motivos, un método eficiente de clasificación, que considere un número suficiente de patrones para una movilidad “natural” de la prótesis que requiera de poco costo computacional para que la clasificación se haga en “tiempo real” mejorará el desempeño de la prótesis, y al mismo tiempo abre posibilidades para diferentes aplicaciones en donde la clasificación de patrones es crucial.

1.2 Justificación

En años recientes se ha realizado un esfuerzo en la búsqueda de un medio preciso y computacionalmente eficiente para la clasificación de señales mioeléctricas. Existen diferentes métodos que han sido estudiados, ejemplo de ellos son el análisis discriminante lineal, (LDA, *Linear Discriminant Analysis*), los modelos ocultos de Markov (HMM, *Hidden Markov Models*), el modelo de mezcla Gaussiana (GMM, *Gaussian Mixture Model*), redes neuronales artificiales (ANN, *Artificial Neural Network*), perceptrón multicapa (MLP, *MultiLayer Perceptrón*), máquinas de soporte de vectores (SVMs, *Support Vector Machines*), entre otros (Chan y Englehart, 2005; Oskoei y Hu, 2008; Miller *et al.*, 2013; Geethanjali, 2016; Dhindsa *et al.*, 2019; Hassan *et al.*, 2019).

Las SVMs son un método relativamente novedoso con un trasfondo teórico fuerte del que ha incrementado su popularidad como herramienta para tareas de aprendizaje de máquinas que involucran clasificación y regresión. Con la finalidad de revisar la exactitud de los métodos disponibles, Oskoei y Hu, (2008) evalúan una SVM que utiliza diferentes kernel, aplicado a la clasificación de señales mioeléctricas de brazo comparado con LDA y MLP, demostrando que es superior, además que el costo computacional es menor, como se observa en la Figura 1.1, donde se muestra que la SVM tiene una mejor exactitud promedio en la clasificación al compararse directamente con LDA y dos versiones diferentes de MLP.; variando el tipo de características extraídas de la señal; las características utilizadas para la comparación fueron MAV (promedio del valor absoluto), WL (longitud de onda), SSC (cambios de signo de pendiente), ZC (cruces por cero), valor RMS de la señal y coeficientes AR (coeficientes de autoregresión A1 y A2); en tres diferentes pruebas, la primera considera

solamente MAV; la segunda MAV+WL+SSC+ZC y la tercera considera el valor RMS y coeficientes AR.

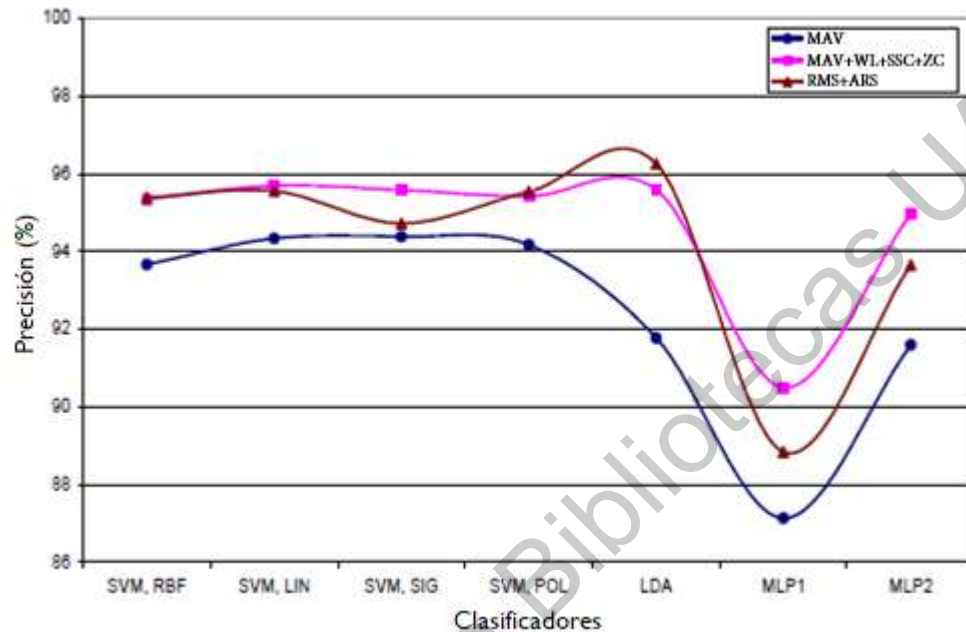


Figura 1.1. Gráfica comparativa del desempeño de 7 clasificadores (Oskoei y Hu, 2008).

Una mejor clasificación de las señales, mejorará el desempeño de la prótesis por distintos motivos, por una parte, reduce el tiempo de entrenamiento que tendrá el usuario antes de poder manejar completamente la prótesis, por requerir un mínimo de concentración para el uso de ésta; por otra parte, si la clasificación es rápida, mejorará sin duda alguna el control de la prótesis. Debido a estos motivos se decidió realizar el presente trabajo.

2 Antecedentes

El progreso en la tecnología de control a partir de señales mioeléctricas (MESs, por sus siglas en inglés, *MyoElectric Signals*) tomadas de la superficie de la piel, además del diseño de prótesis, también ha incrementado a través de los años, debido al enfoque alternativo de la investigación y el desarrollo de una metodología de control y dispositivos de hardware (Hudgins *et al.*, 1993; Chan *et al.*, 2000; Englehart *et al.*, 2003; Rossi *et al.*,

2015; Pancholi y Joshi, 2018). Éstas han sido usadas para diversas aplicaciones, incluidos diagnósticos clínicos, como fuente de control de dispositivos asistidos y esquemas de simulación eléctrica funcional. En el campo de las prótesis, la extracción de MES permite desde mover una de ellas con una sola función mediante un solo músculo, hasta mover una prótesis multifunción a partir de actividades de un grupo de músculos (Huang y Chen, 1999; Guo *et al.*, 2004; Chan y Englehart, 2005; López-Delis *et al.*, 2015; Tavakoli *et al.*, 2018).

De la misma manera, las máquinas de soporte de vectores han sido estudiadas en años recientes para la clasificación de todo tipo de señales, ejemplo de ello, Zhou, (2010) clasifica señales de modulación digital, utilizando un “kernel radial”; la identificación de las clases se hace “uno contra uno” y “uno contra el resto” del clasificador multi-clase; además adopta el método de selección de parámetros utilizando una rejilla de validación cruzada.

Predecir la estructura tridimensional de una proteína es un problema clave en biología molecular, ramo de estudio donde Chmielnicki *et al.*, (2012) utilizan una SVM como clasificador multiclase para resolver este problema, con un menor costo computacional comparado con otros métodos con la misma exactitud; combinan una SVM con un árbol de decisión binaria, método al que llaman “SVM-BDT”, con un enfoque basado en la relación de reconocimiento alcanzado en el conjunto de datos de entrenamiento.

La señal mioeléctrica como entrada de control ha dominado debido a que se han encontrado grandes ventajas sobre otras entradas, de tal manera que desde los años sesenta se presentan trabajos al respecto. El problema con el uso de estas señales es que, debido al filtrado y la amplificación que se hace de la señal, no se tiene suficiente información para un control confiable, por lo que algunos de los investigadores de las décadas más recientes se han dedicado a la clasificación de las señales, sin pérdida de información; maximizando la exactitud en clasificación y disminuyendo el costo computacional. Por ejemplo, Englehart *et al.*, (1999) recalca que una extracción efectiva de las señales es crucial para la clasificación y propone un ensamble de representaciones basado en tiempo-frecuencia para asegurar la clasificación, utiliza la transformada de Fourier de corto tiempo, la transformada wavelet y el paquete transformada wavelet; clasifica cuatro diferentes señales con dos canales de 256 puntos, muestreando a 1 kHz, cuyo error promedio de clasificación es de 6.25%.

Dos años más tarde, Englehart *et al.*, (2001) presentan un esquema de control de gran exactitud, cuyo método usa un conjunto de características basado en wavelets, para cuatro canales de datos mioeléctricos y reducido en dimensión mediante el análisis de componentes principales.

Años más tarde, Al-Assaf y Al-Nashash, (2005) utilizan la técnica del valor promedio con un análisis de componentes principales y un análisis de tiempo-frecuencia para la segmentación; lo hacen mediante un análisis wavelet multi-resolución para la extracción de características y una red neuronal para la clasificación de cuatro señales de codo y muñeca, desde el bíceps y el tríceps, con 5.1% de error, con dos canales.

En 2006, Rasheed en su tesis, utiliza características en el dominio del tiempo, datos de la derivada discreta de primer y segundo orden, y datos en lo que llama, dominio Wavelet, refiriéndose al dominio tiempo-frecuencia en el que se considera la transformada Wavelet. Además, implementa un enfoque de fusión de clasificador híbrido, con la técnica del vecino más cercano para una combinación de lógica difusa y redes neuronales, reduciendo así el número de errores en la clasificación.

En su tesis de maestría, Fougner, (2007), diseña un controlador con base en señales mioeléctricas para prótesis de la extremidad superior, con un clasificador red MLP de 8 nodos, considerando 4 ángulos de giro para diferenciar y un error RMS (por sus siglas en inglés, Root Mean Square) de 20 al 37 %.

En 2007, Liu *et al.*, proponen un clasificador llamado “Cascade Kernel Learning Machine (CKLM)”, en el que hacen la extracción de características por un modelo ARM y un histograma de tres sensores. Para la clasificación utilizan GDA y SVM; el primero reduce la dimensionalidad de las características de entrada y la selección de las características discriminatorias, después el SVM combinado con una estrategia de uno contra uno es ejecutado para clasificar. Por cascada SVM con GDA mapean no linealmente las características de entrada por medio de una función radial, con la que obtienen una separación lineal óptima de hiperplanos con un amplio margen de separación entre cada una de las clases; la clasificación tiene un 93.51% de exactitud, para ocho clases, con cinco músculos, con una ventana del patrón de 20.7 ms.

Años más tarde, Álvarez Illán, en 2009, realiza una tesis doctoral con varias técnicas novedosas para la ayuda en el diagnóstico por computadora del Alzheimer, utilizando un clasificador basado en SVMs, cuya extracción de características la realizan por factorización, para posteriormente hacer un análisis de componentes principales y una reducción de dimensionalidad mediante el criterio de Fisher.

La mayoría de los métodos de clasificación no incluyen una clase para “no hacer nada”, es decir, evitar algún movimiento en caso de que el clasificador tenga dudas; para corregir esto, Erik Scheme, (2010) propone un sistema de clasificación multiexperto “uno contra uno”, el cual consiste en un clasificador binario de $N \times (N-1)$ (donde N es el número total de clases) el cual determina la salida más probable entre cada par de clases- Estas salidas son subsecuentemente combinadas para producir una salida final, incluida la habilidad de no hacer nada (por defecto) en caso de confusión; utiliza 12 electrodos y diferencia entre 12 clases.

Con la finalidad de mejorar la exactitud en la clasificación de las señales, algunos investigadores combinan diferentes herramientas junto con las SVMs, ejemplo de ello son: Alkan y Günay, (2012) utilizan un análisis discriminante y un clasificador SVM para clasificar 4 MESs generadas por el bíceps y el tríceps; con la premisa de que cada señal tiene un patrón singular, los vectores característicos son generados mediante el uso del valor absoluto promedio (MAV), el análisis discriminante utiliza cinco diferentes aproximaciones y tiene un rango de exactitud de 96-98%, la representación del espacio la hacen basados en la transformada discreta de wavelet, con una frecuencia de muestreo de 1 kHz.

En Rasool *et al.*, (2014) analizan a la señal mioeléctrica como una serie de tiempo estocástica, encontrando que la señal es heteroscedástica, es decir, los residuos de modelado AR (autoregresivo) presentan una varianza variable en el tiempo; modelan la señal como un proceso generalizado autoregresivo condicional heteroscedástico autoregresivo (AR-GARCH, *Autoregressive-generalized autoregressive conditiona heteriscedastic*), en donde los parámetros estimados por el modelo, son los que se clasifican, obteniendo una $p < 0.01$, para 12 diferentes movimientos medidos a través de cinco sensores, con una ventana de tiempo para el patrón de 200 ms.

McCool *et al.*, (2015) demuestran que algunas técnicas de mejora espectral pueden ser configuradas para mejorar la clasificación de un sistema de control mioeléctrico basado en reconocimiento de patrones; señalan que cuando un sujeto se encuentra en descanso, la potencia en señales de EMG eleva sus características de ruido.

El desarrollo de sistemas de control mioeléctrico con base en reconocimiento de patrones ha sido gobernado por el deseo de una alta exactitud en la clasificación de las señales de EMG. Sin embargo, como ya se mencionó, las propiedades no estacionarias de éstas en ajustes de la vida real, obstaculiza las aplicaciones clínicas del reconocimiento de patrones mioeléctricos para el control de prótesis. No obstante, esta exactitud es solo definida para ejemplos conocidos de clases, mientras que el uso de prótesis activas produce invariablemente, contracciones extrañas.

Liu, (2015) desarrolla un sistema adaptativo de reconocimiento de patrones, con el objetivo de entrenar un clasificador en línea con los datos de prueba sin supervisión, proporcionando un mecanismo de auto corrección para suprimir no-clasificaciones, con base en SVMs; con la finalidad de mejorar el control de prótesis que utilicen este método.

En el mismo año, AlOmari y Liu proponen un sistema híbrido inteligente de reconocimiento de patrones para clasificar ocho movimientos de la mano, combinando SVMs con dos algoritmos evolucionarios, uno genético y otro de optimización de nubes de partículas. Dicho algoritmo tiene un gran desempeño en las tareas de aprendizaje, ya que cuenta con una óptima selección de parámetros de la función radial base (RBF, Radial Based Function) y la selección del nivel de descomposición óptimo para una función Wavelet madre (AlOmari y Liu, 2015).

Por otra parte, McCool *et al.*, demuestran que mediante técnicas de mejora espectral se puede incrementar la calidad de la clasificación de señales de EMG para el control mioeléctrico basado en reconocimiento de patrones; realizan su estudio comparando los resultados al usar técnicas estadísticas mínimas desarrolladas en el procesamiento del habla y métodos de eliminación de ruido electromiográfico, (wavelets y modo empírico de descomposición); del cual concluyen que usando el método de mejora espectral IMCRA (por sus siglas en inglés, Improved Mínima-Controlled Recursive Averaging) se obtiene una

mejor clasificación (McCool *et al.*, 2015). Esto último es importante, ya que, con una mejor clasificación, se pueden tener mejoras en el desenvolvimiento de la prótesis, al reducir el tiempo de entrenamiento del usuario, por requerir un mínimo de concentración para el uso de ésta.

Sin embargo, ya que las SVMs tienen un alto costo computacional cuando se tienen demasiadas clases; cada una de estas clases contiene una gran cantidad de características llamadas atributos. Algunos de estos no son relevantes y deben eliminarse; ya que en la clasificación, cada característica tiene un efecto sobre la exactitud, costo, y tiempo de aprendizaje del clasificador (Khan and Baig, 2015).

El uso de técnicas de selección de características es muy común, casi tanto como los de reducción de características, porque estos algoritmos dan como resultado las características que contienen la información más relevante de la señal; con esta reducción se mejora la exactitud de la clasificación y la reducción de la complejidad computacional (Zhang *et al.*, 2019; Xue *et al.*, 2020).

Para la selección de características se usan una gran variedad de algoritmos, tanto en la forma supervisada como en la no supervisada. Sin embargo, los más usados son los primeros, debido a que en los datos se cuenta con la etiqueta de clasificación a cada muestra. Los algoritmos de selección de características de la forma supervisada, se pueden clasificar en filtros, envoltura, métodos y modelos embebidos. Los filtros son independientes de cualquier método de aprendizaje, porque la atención se centra en las características generales de los datos; no son costosos computacionalmente y tienen una buena capacidad de generalización. Las técnicas de envoltura y los métodos integrados requieren de un algoritmo de aprendizaje. Por otra parte, existe una tendencia a mezclar los algoritmos, como en el caso de los métodos embebidos, que suelen combinar dos o más métodos de diferentes orígenes conceptuales (Remeseiro y Bolon-Canedo, 2019).

Entre los métodos de filtros se encuentran: Relief (Robnik-Šikonja y Kononenko, 2003; Sun y Wu, 2008), Fisher Score (Duda *et al.*, 2000) e Information Gain (Cover y Thomas, 1991; Peng *et al.*, 2005). Las técnicas de envoltura incluyen reglas Bayesianas

(Kohavi y John, 1997; He *et al.*, 2020; Prasad *et al.*, 2020) y algunos métodos embebidos se describen en Ma y Huang, (2008).

Relief ha sido considerado uno de los métodos más exitosos, debido a su simplicidad y efectividad (Sun y Wu, 2008). Rodríguez-Lujan *et al.*, (2013) lo aplican para la reducción de dimensionalidad aplicado a datos de espectrometría de masas para la identificación del odor de 13 sujetos diferentes, también Zafra *et al.*, (2010) lo utilizan para solucionar el problema de categorización de imágenes de tres reconocidos conjuntos de datos. Recientemente Subbotin, en 2018 proponen una modificación a este método, cuyo propósito fue una aceleración significativa de los cálculos.

Por otra parte, autores como Rodríguez *et al.*, (2014) proponen técnicas de Optimización en Colonias de Hormigas y la Teoría de los Conjuntos Aproximados para la selección de rasgos aplicado en el pre-procesamiento de datos para pronosticar, de forma automática, las temperaturas diarias en el Centro Meteorológico de Camagüey. En el mismo año, Nazir *et al.*, combinan Optimización de Enjambre de Partículas (PSO, por sus siglas en inglés Particle Swarm Optimization) con algoritmos genéticos (GA, por sus siglas en inglés Genetic Algorithm) para seleccionar las características más importantes en la clasificación de género, para después hacer la clasificación utilizando una SVM y obteniendo 98.3% de exactitud. De la misma forma, pero años más tarde, en 2019, Chen *et al.*, Wei *et al.*; Xiong *et al.* combinan PSO con otras técnicas para seleccionar un subconjunto de características óptimas para la clasificación.

Un ejemplo de un método embebido es el utilizado por Wiesław en 2019, quien aplica un método de selección de características generacionales con base en estructuras de árboles con aplicación recursiva, para analizar datos médicos artificiales y del mundo real.

Recientemente, Wang *et al.*, en 2019 presenta un nuevo método para la selección de características con base en optimización de colonias bacterianas con población multidimensional; los datos seleccionados son utilizadas para clasificar once cancerígenos con características de múltiples clases y tamaños variables.

Xue *et al.*, (2020) proponen un algoritmo de PSO basado en parámetros y estrategias autoadaptativas para la selección las características más importantes a gran escala; el algoritmo propuesto es probado con varios clasificadores, probando su efectividad al mejorar la exactitud obtenida con cada uno de ellos. Por otra parte, Zhang *et al.*, (2020) estudia un nuevo enfoque de selección de características de objetivos múltiples; señalan que el algoritmo es capaz de competir con aquellos basados en colonias de abejas, GA, PSO, evolución diferencial y colonias artificiales.

Con respecto al tratamiento de señales biomédicas, en 2014, Liu propone un enfoque basado en filtro de campo aleatorio de Markov combinado con un algoritmo de búsqueda ortogonal directa para evaluar la contribución cada señal de EMG; señalando que es un enfoque independiente del tipo de algoritmos de clasificación y características, que permite reducir la información redundante a través de los diferentes canales y además cruzar diferentes características. Para ayudar en el reconocimiento de patrones de señales de electrocardiograma, Lu *et al.*, (2016) emplea un algoritmo genético modificado que utiliza una estrategia de búsqueda de rango variable y descomposición en modo empírico para realizar una exploración dinámica y optimizar los subconjuntos de características estadísticas.

Chatterjee *et al.*, (2019) proponen una técnica de selección de características basada en una matriz de discernibilidad difusa, para determinar un subconjunto de características de señales de electroencefalograma (EEG) de imágenes motoras y clasificarlas posteriormente utilizando una SVM.

3 Hipótesis

La extracción de diferentes características combinadas en un algoritmo clasificador de señales de EMG con base en SVMs mejora el resultado del procesamiento de las señales utilizadas para el control de una prótesis transtibial con respecto a otros algoritmos de clasificación como redes neuronales y análisis discriminante lineal.

4 Objetivos

4.1 Objetivo general

Desarrollar un algoritmo clasificador de señales de EMG con base en SVMs que mejore el resultado del procesamiento de señales utilizadas para el control de una prótesis transtibial con respecto los clasificadores ANN y LDA.

4.2 Objetivos particulares

1. Identificar las características que se pueden extraer de una señal EMG.
2. Revisar los algoritmos de selección de características para elegir uno que permita reducir la dimensión de la matriz de entrada.
3. Analizar, evaluar y seleccionar un algoritmo de reducción de características, para reducir y mejorar la dimensión de la matriz de entrada.
4. Implementar diferentes variantes de los algoritmos encontrados para la clasificación y seleccionar el que exhiba un menor tiempo de respuesta y una mejor exactitud.
5. Comparar el algoritmo diseñado con los clasificadores ANN y LDA.

5 Fundamentación teórica

Día con día, la tecnología y la computación están más presentes en nuestra rutina, por lo que se puede observar que la robótica lo hace de la misma manera, hasta llegar al punto en que también toma parte en el cuidado de nuestra salud. Las prótesis transtibiales (PTT) inteligentes son controladas por microprocesadores que incorporan una o más señales de EMG, pero, al ser ésta no estacionaria, es difícil de analizar; además de requerir una la colocación y ajuste de electrodos para medir las señales. Por estos motivos, numerosos investigadores centran su estudio en diferentes métodos de clasificación de señales, para hacer un control más simple de la PTT.

Las SVMs propuestas por (Vapnik y Corinna, 1995) son derivadas de la idea de generar un hiperplano óptimo con el máximo margen entre dos clases, cuya estrategia se basa en el principio de minimización de riesgo estructural (SRM, *structural risk minimization*), el cual no solo minimiza el riesgo empírico (errores de entrenamiento), sino que también minimiza el error global durante el entrenamiento. Hoy en día, uno de los usos que se les da es la clasificación de MESs.

5.1 Electromiografía

El movimiento y la posición de las extremidades son controlados por señales eléctricas que viajan entre los músculos y el sistema nervioso central; sin embargo, cuando se presentan condiciones patológicas en el sistema motor, las características de la señal cambian, es por eso que se hace un estudio cuidadoso de la señal eléctrica del músculo de la extremidad residual a través de un electromiograma.

La electromiografía se define como el registro y la interpretación de los potenciales bio-eléctricos registrados en los músculos. Desde la década de los setentas, se han utilizado MESs como señales de control para prótesis accionadas por motores eléctricos, también llamadas prótesis mioeléctricas; en las cuales se utilizan señales principalmente de los músculos de la extremidad residual (Sandoval-Castro, 2011).

Una señal EMG es una representación del potencial eléctrico generado por la despolarización de la membrana de la fibra muscular externa (el sarcolema). Esta detección involucra el uso de electrodos superficiales (sEMG) o intramusculares (iEMG) que son colocados a cierta distancia desde la fuente. El tejido que separa a las fuentes de los electrodos actúa como conductor de volumen, el cual determina las características de las señales detectadas (Farina y Merletti, 2004) A continuación se describen los elementos para un sistema de adquisición de información de MESs.

5.1.1 Sistema de adquisición

El objetivo del sistema de adquisición y procesamiento de señal es proveer de una MES de alta calidad donde información específica por la postura o contracción del músculo puede ser extraída y asociada con el comando de control deseado. La electrónica para la adquisición de ésta consiste en canales, filtros, amplificadores y convertidores analógico-digítales (Hakonen *et al.*, 2015).

5.1.1.1 Número de electrodos

Los electrodos para electromiografía (EMG) son los mismos utilizados para electrocardiograma (ECG) y en algunas ocasiones, también son utilizados para extraer señales de electroencefalograma (EEG). Presentan diámetros que varían desde 0.3 cm a 1 cm; y consisten en botones metálicos de contacto hecho de plata – cloruro de plata (Ag/AgCl) en la parte alta de la columna, el cual se rellena con un gel o pasta conductiva. Mantienen su posición mediante un disco de hule espuma cuya superficie tiene una sustancia adhesiva.

El número óptimo de electrodos para una interfaz de sEMG ha sido estudiado principalmente para señales en el brazo. En condiciones de laboratorio, la calidad de la clasificación incrementa con tres o cuatro canales bipolares. Sin embargo, cuando los electrodos se mueven, la recomendación aumenta de cuatro a seis, con la finalidad de acomodar una mitad longitudinalmente y la otra transversalmente. De cualquier manera, el número óptimo de electrodos probablemente dependa de la anatomía de la persona (Farrell y Weir, 2008).

Un estudio realizado para conocer la mejora de la exactitud de la clasificación en 2019, (Toledo-Pérez et al., 2019) indica que los resultados obtenidos con dos y tres electrodos no varían mucho. Al añadir un canal adicional, la exactitud de la clasificación aumenta en promedio de 5%; por lo que se considera que seguir aumentando la cantidad de canales no mejora significativamente la exactitud obtenida.

5.1.1.2 Rango de filtrado y muestreo

La amplitud de una MES usualmente se encuentra por debajo de los 10 mV, lo que la hace sensible a instrumentos, y hace necesario amplificarla de 100 a 5000 veces, además que deber ser convertida a señal digital. Comúnmente, el pico oscila entre 5 y 20 Hz, con la finalidad de eliminar las pequeñas variaciones en la señal causadas principalmente por el movimiento de los instrumentos y sus cables (Hakonen *et al.*, 2015).

5.1.2 Algoritmos pre-procesados para clasificación

Los algoritmos usados para pre-procesar datos de señales MES incluyen: el análisis de componentes principales (PCA, por sus siglas en inglés, Principal Component Analysis) y el análisis de componentes independientes (ICA, por sus siglas en inglés, Independent Component Analysis). En el primero, los datos sEMG son rotados por matrices de proyección de clases específicas para decorrelacionar los datos antes de que las características sean extraídas. Las matrices de proyección aproximan algunos datos de baja dimensión no lineales. Por otra parte, el segundo puede reducir el efecto *crosstalk*, es decir, ayuda a reducir el efecto de la interacción entre señales cercanas. ICA estima un conjunto de señales independientes desde una mezcla de señales dadas mediante una estimación de una matriz sin mezclar (Hakonen *et al.*, 2015).

5.1.3 Decodificación de información mioeléctrica

Una señal mioeléctrica $s(t)$ está formada por la superposición de potenciales de acción individuales (AP, Action Potentials) generados por descargas irregulares de unidades motoras activas (MU, motor units) en un músculo, medidas en μV . (Merlo *et al.*, 2003) modela una MES superficial como se muestra en las ecuaciones (1) y (2):

$$s(t) = \sum_j MUAPT_j(t) + n(t) \quad (1)$$

$$s(t) = \sum_j \sum_i k_j f\left(\frac{t - \theta_{ij}}{\alpha_j}\right) + n(t) \quad (2)$$

Donde k_j es un factor de amplitud para la j th unidad motora, $f(\bullet)$ la forma de la descarga del potencial de acción, θ_{ij} el tiempo de ocurrencia de un MUAP, α_j un factor de escala y $n(t)$ es el ruido adicional. Debido a esto, un alto número de MUAPs superpuestos y la naturaleza de la descarga de MU, una señal superficial suele ser considerada como compleja y estocástica no estacionaria; en otras palabras, no puede predecirse y no es repetitiva. Sus características son extremadamente dependientes del nivel y la duración de la contracción, estado del músculo dinámico o estático, fatiga y sudor de la piel, ya que una piel sudorosa puede presentar únicamente 0.5 k Ω de impedancia, mientras que una piel seca hasta 20 k Ω (Rothstein *et al.*, 2005).

Las estrategias de control de las señales MES pueden ser separadas en dos grupos principales, las basadas en un patrón de reconocimiento y las de reconocimiento sin patrón. La Figura 5.1 ilustra los pasos para cada una de las estrategias de control.

5.2 Control mioeléctrico con base en reconocimiento de un patrón

El control mioeléctrico que se basa en el reconocimiento de patrones calcula vectores característicos con diferentes segmentos de las señales; los cuales son utilizados como entrada del clasificador de control y así predecir las diferentes posturas. En algunas ocasiones, los electrodos son acompañados por pre-amplificadores para diferenciar las señales que son de interés. Después de ser amplificadas, filtradas y digitalizadas (con ayuda de instrumentos mioeléctricos), las señales pasan a los módulos mostrados en la Figura 5.1; en la cual se expresan diferentes procesos de sistemas de control mioeléctrico; uno basado en reconocimiento del patrón de la señal y dos más sin patrón.

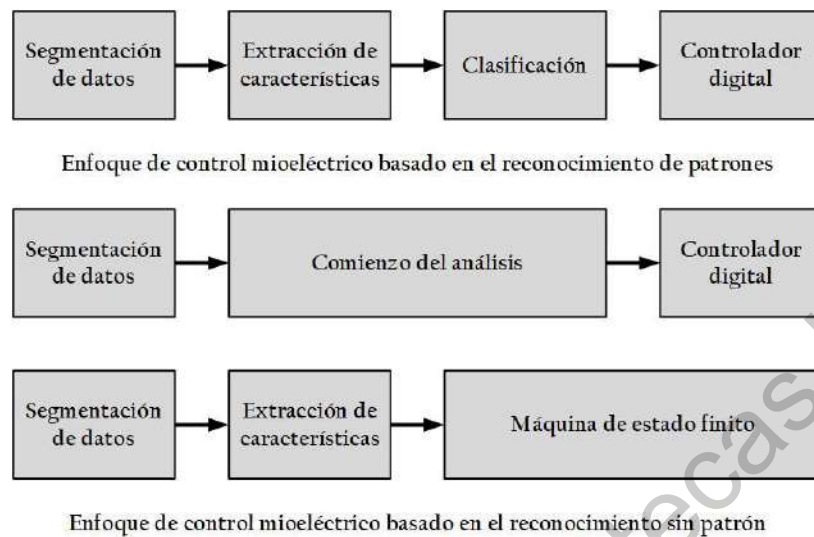


Figura 5.1. Diagrama esquemático de métodos de control de señales EMG (Hakonen *et al.*, 2015).

5.2.1 Segmentación de datos

Es el bloque comprendido por varias técnicas y métodos usados para manejar los datos antes de extraer las características, con la finalidad de mejorar la calidad y la respuesta en el tiempo. Un segmento se define como un espacio de tiempo para adquirir datos considerados para la extracción de características. Debido a las restricciones de tiempo real, una longitud de segmento más el tiempo de procesamiento para generar los comandos de control debe ser igual o menor a 300 ms (Oskoei y Hu, 2007).

Una MES está comprendida por dos estados:

- i) Estado transitorio, emanando de una ráfaga de fibras, en otras palabras, como cuando un músculo va desde el reposo hasta un nivel de contracción voluntaria.
- ii) Estado estable, emanando durante una contracción mantenida constante de un músculo.

5.2.2 Extracción de características

Es la etapa donde se procesan y presentan características pre-seleccionadas para clasificar, lo que mejora la eficiencia de la clasificación; es uno de los módulos más críticos. Los arreglos de señales MES son mapeadas en vectores característicos de pequeñas dimensiones, ya que estas describen la información contenida en la señal más eficientemente que un arreglo de la señal aleatoria y compleja. Las características se clasifican de acuerdo al dominio donde son calculadas en Hakonen *et al.*, (2015):

- 1) Características en el dominio de tiempo (TD, Time Domain).- Son fáciles de calcular al no necesitar transformaciones matemáticas; son basadas en la amplitud de la señal, por lo que son sensibles al ruido y los instrumentos. Phinyomark *et al.*, (2012) las dividen en métodos de información de energía y complejidad, de información de frecuencia, de predicción de modelo y dependientes de tiempo.
- 2) Características en el dominio de frecuencia o espectral (FD, Frequency Domain).- Pueden ser usados para estimar la fatiga muscular, producción de fuerza y cambios en la unidad motora; son calculadas desde la densidad espectral de potencia, las cuales pueden ser estimadas usando métodos paramétricos.
- 3) Características en el dominio de escala de tiempo o frecuencia de tiempo (TFD, por sus siglas en inglés Time Frequency Domain).- Incluyen transformada de Fourier de corto tiempo y las transformadas continua, discreta y estacionaria de Wavelet.
- 4) Características en el dominio espacial (SD, Spatial Domain).- Ayudan a mejorar la distinción entre posturas y niveles de fuerza.

5.2.2.1 Valor absoluto medio (MAV, por sus siglas en inglés Mean Absolute Value)

Consiste en obtener el promedio de la suma de los valores absolutos de los elementos que conforman la señal de entrada. Considere N el número de elementos:

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (3)$$

5.2.2.2 Cruces por zero (ZC, por sus siglas en inglés Zero Crossings)

Consiste en contar el número de veces que la señal cruza por cero, ya sea que vaya de un valor negativo a uno positivo o viceversa:

$$ZC = \sum_{i=1}^N f(x) \quad (4)$$

donde:

$$f(x) = \begin{cases} 1, & \text{si } x_i > 0 \ \& \ x_{i+1} < 0 \\ 0 & \text{o } x_i < 0 \ \& \ x_{i+1} > 0 \\ 0 & \text{cualquier otro caso} \end{cases} \quad (5)$$

5.2.2.3 Longitud de forma de onda (WL, por sus siglas en inglés Waveform Length)

Es la variación acumulada de una señal; en otras palabras, indica el grado de variación de la misma, con un total de N elementos está dada por:

$$WL = \sum_{i=1}^{N-1} (|x_{i+1} - x_i|) \quad (6)$$

5.2.2.4 Cambios de signo de pendiente (SSC, por sus siglas en inglés Slope Sign Changes)

Cuenta el número de veces que la pendiente de la señal cambia de signo, lo que hace necesario evaluar dónde está, dónde estaba y hacia dónde va la señal. Se calcula:

$$SSC = \sum_{i=1}^N f(x) \quad (7)$$

donde:

$$f(x) = \begin{cases} 1, & \text{si } x_i < x_{i+1} \ \& \ x_i < x_{i-1} \\ 0 & \text{o } x_i > x_{i+1} \ \& \ x_i > x_{i-1} \\ & \text{cualquier otro caso} \end{cases} \quad (8)$$

5.3 Selección de características

La selección de características consiste en identificar un conjunto de variables que son relevantes para la predicción de la respuesta del algoritmo un el proceso de reconocimiento de patrones, por lo que es una herramienta importante en estadística y *machine learning*. Sin embargo, es un proceso difícil cuando el número de variables se aproxima o excede el número de muestras (Fisher y Mehta, 2014), lo cual es usualmente el caso de los conjuntos de datos de las señales de EMG. Los algoritmos utilizados en este trabajo de tesis se describen a continuación:

5.3.1 Relief

Es un método multi-variante que selecciona las características que son más importantes entre diferentes clases. Está basado en sus vecinos, el algoritmo realiza dibujos repetidamente a la muestra y asigna el mayor peso a las características que ayudan a discriminarla de muestras más cercanas de diferentes clases (Wang y Makedon, 2004). Considerando la probabilidad para que el peso de una característica y los atributos puedan

ser tratados como independientes uno del otro (Hall, 1999), el algoritmo se puede describir de la siguiente forma:

$$\begin{aligned} \text{Relief}_x &= P(\text{valor diferente de } X \mid \text{diferentes clases}) \\ &\quad - P(\text{valor diferente de } X \mid \text{misma clase}) \end{aligned} \quad (9)$$

5.3.2 SBMLR, Sparse Bayesian Multinomial Logistic Regression

Desarrollado por Cawley *et al.*, en 2007, es un método de regresión logística multinomial dispersa, donde el parámetro de regularización usual es integrado fuera analíticamente. Ellos adoptan la aproximación de Laplace, para la integral en la interpretación Bayesiana de la función objetivo regularizada $P(D)$, correspondiente a la distribución posterior Gaussiana para el modelo de parámetros, centrada en su valor más probable (ω^{MP}), mediante:

$$L(\omega) = L(\omega^{MP}) + \frac{1}{2} (\omega - \omega^{MP})^T A (\omega - \omega^{MP}), \quad (10)$$

donde $A = \nabla \nabla L$ es el Hessiano de la función objetivo regularizada, utilizando la aproximación de Laplace. La evidencia de un modelo de regresión logística multi-nomial bajo el esquema de regularización Bayesiano está dada por:

$$-\log \{D\} = E_D + W \log E_W - T + \text{constante}, \quad (11)$$

y donde:

$$T = -\log \left\{ \frac{\Gamma(W)}{2^W} + \frac{1}{2} \log |A| \right\}. \quad (12)$$

La función objetivo $P(D)$ se define como:

$$P(D) = \frac{1}{Z\omega} \int \exp\{-L\} d\omega. \quad (13)$$

5.4 Clasificación y control

Para la etapa de control se debe reconocer el patrón de la señal y después clasificarlo en categorías pre-definidas. Esta clasificación debe ser suficientemente robusta e inteligente, para que la prótesis pueda adaptarse rápidamente a los cambios durante largos tiempos de operación; con la finalidad de obtener el valor de las variables en tiempo real. El algoritmo a utilizar para clasificar con las máquinas de soporte de vectores.

5.4.1 Máquinas de Soporte de Vectores

Las máquinas de soporte de vectores son muy utilizadas como algoritmos de clasificación, ya sea movimientos corporales, imágenes, sonidos, etc. Para esta función requieren de señales de entrada que posteriormente serán procesadas antes de pasar por el algoritmo de clasificación. Una SVM construye un hiperplano de separación óptimo en un espacio de características que se dice es de alta dimensión, al ser mapeadas las entradas utilizando funciones no lineales; para poder distinguir entre dos o más tipos de objetos.

En una SVM, el entrenamiento del algoritmo es reformulado como un problema para resolverse utilizando programación cuadrática (QP, Quadratic Programming), cuya solución es global y única. Para datos de entrenamiento de entrada $(x_1, y_1), \dots, (x_m, y_m) \in R^N \times \{\pm 1\}$, donde x_i corresponde al valor de entrada y y_i el valor asignado del tipo de objeto al que pertenece (también conocido como clase); estos datos, si no son linealmente separables, son mapeados mediante $\phi: R^N \mapsto F$ dentro de un espacio característico y ω corresponde a la matriz de entrenamiento. De esta manera, los hiperplanos lineales obtenidos que separan los tipos de objetos, pueden verse como:

$$\omega \times \phi(x) + b = 0 \quad \omega \in R^N, \quad b \in R \quad (14)$$

Para construir un hiperplano óptimo con el máximo valor del margen de separación y un error ξ cerrado en el entrenamiento del algoritmo, el problema QP se plantea de la siguiente manera:

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m \xi_i \quad (15)$$

donde:

$$y_i (\omega \times \varphi(x_i) + b) \geq 1 - \xi_i, \quad i = 1, \dots, m.. \quad (16)$$

El primer término en la función costo genera un margen máximo de separación entre las clases, mientras que el segundo provee una cota superior para el error en los datos de entrenamiento. Finalmente, la constante $C \in [0, \infty)$ crea una compensación entre el número de muestras mal clasificadas en el conjunto de entrenamiento y la separación del resto de muestras con un margen máximo.

5.4.2 Enfoque de redes neuronales

El principal motivo para usarlo es el deseo de implementar tareas de aprendizaje a través de la inteligencia artificial (AI, *Artificial Intelligence*). La ventaja que tiene es la habilidad de representar relaciones lineales y no-lineales, y aprender esas relaciones directamente de los datos modelados.

5.4.3 Enfoque de algoritmos difusos

Los sistemas lógicos difusos (también conocidos como *Fuzzy*) son capaces de descubrir patrones en datos que no son fácilmente detectables; más aún, este abordaje explota la tolerancia a la imprecisión, incertidumbre y verdad parcial, para lograr soluciones tratables, robustas y de bajo costo para la clasificación.

5.4.4 Control mioeléctrico con base en reconocimiento sin patrón

Este tipo de control incluye control proporcional, control del umbral, análisis de inicio y máquinas de estado finito. El número de funciones que pueden ser controladas por esta clase de control es menor que con el control basado en reconocimiento de patrón. Éstos tienen una estructura simple, y en su mayoría han sido desarrollados en el control ON/OFF o en navegación.

5.5 Mecánica del pie

La sección transtibial del cuerpo humano está compuesta por el pie y la sección de la pierna debajo de la rodilla. La articulación conforman la pierna con el pie, es del tipo de artrodia, debido a que los huesos de las articulaciones tienen superficies planas y sólo realizan pequeños movimientos de desplazamiento, como se muestra en la Figura 5.2 (Barone *et al.*, 2012).

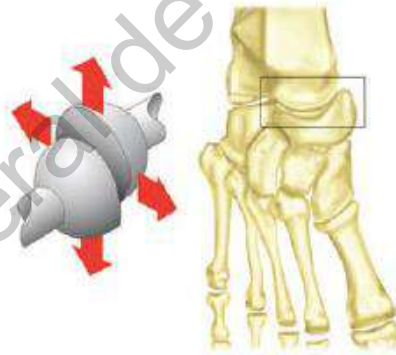


Figura 5.2. Articulación artrodia (Barone *et al.*, 2012).

El cuerpo humano realiza tres tipos de palancas. La pierna, junto con el tobillo y pie realizan una palanca de segundo género, que es aquella en la que la resistencia se halla entre el punto de apoyo y el de la potencia, como se muestra en la Figura 5.3 (Barone *et al.*, 2012).



Figura 5.3. Palanca del pie. (A, punto de apoyo, R, punto de resistencia y P, punto de potencia) (Barone *et al.*, 2012).

El pie, el eslabón más distal de la extremidad inferior, sirve para conectar el organismo con el medio que lo rodea, es la base de la sustentación del aparato locomotor y tiene la capacidad de convertirse en una estructura rígida o flexible en función de las necesidades para las que es requerido y las características del terreno en que se mueve (Viladot-Voegeli, 2003).

Cinemática

El pie posee un conjunto de articulaciones que le permiten movimiento en los tres planos del espacio:

- Flexión – extensión
- Rotación interna (aducción) – rotación externa (abducción)
- Pronación – supinación

Por otra parte, desde un punto de vista funcional podemos agruparlas en dos grandes grupos:

1. Acomodo.- Amortiguan el choque del pie con el suelo y lo adaptan a las irregularidades del terreno; corresponden a las articulaciones del tarso y tarsometatarsianas.
2. Movimiento.- Tienen una función dinámica y son fundamentales para la marcha; corresponden a las del tobillo y los dedos.

5.6 Prótesis de pie

La prótesis es la más vieja de las ciencias de rehabilitación tecnológica, tanto como el tiempo en que las personas han sobrevivido a la pérdida de las extremidades; por lo que han existido personas motivadas a reemplazar las funciones perdidas con ellas mediante la construcción de prótesis.

En la actualidad, las prótesis se pueden clasificar según el método de accionamiento para generar el movimiento (Andrade *et al.*, 2014):

- ✚ **Prótesis pasivas y completamente pasivas:** Sólo se pueden mover y colocar en posiciones deseadas a través de fuerzas externas; generalmente son usadas estética, ya que el uso de éstas puede tener un efecto psicológico positivo.
- ✚ **Prótesis accionadas por cuerpo:** Ésta clase de prótesis es accionada al forzar el movimiento de algunas partes del cuerpo, como los hombros; mediante los cuales se puede controlar la extremidad artificial.
- ✚ **Prótesis accionadas externamente:** Son aquellas energizadas por alguna fuente externa de energía, por ejemplo, baterías. Estas prótesis son controladas usualmente por el movimiento de la estructura natural restante o por una actividad muscular eléctrica derivada de un grupo de músculos elegidos para medir.
- ✚ **Prótesis híbridas:** Éstas suelen combinar funciones de control de extremidades con un sistema de control vía arnés. Son llamadas híbridas porque combinan dos tipos de control en la misma prótesis.

5.7 Análisis de desempeño de un clasificador

5.7.1 Matrices de confusión

Es una herramienta que sirve para evaluar el desempeño de un clasificador; contiene información acerca de los valores y las clasificaciones calculadas por un algoritmo de clasificación. Funciona a través de un conteo de aciertos y errores de cada una de las clases en la clasificación; de esta forma se puede corroborar si el algoritmo está clasificando mal las clases y en qué medida lo hace. La matriz de confusión se puede acomodar como se muestra en la Tabla 5-1.

Tabla 5-1. Diseño general de una matriz de confusión.

		Predicción	
		<i>Positivos</i>	<i>Negativos</i>
Observación	<i>Positivos</i>	Verdaderos positivos (VP)	Falsos negativos (FN)
	<i>Negativos</i>	Falsos positivos (FP)	Verdaderos negativos (VN)

5.7.2 Especificidad

La especificidad (SPE, por su nombre en inglés), es la capacidad del algoritmo de clasificación para identificar que el caso en cuestión no pertenece a la clase en la que está siendo analizado si en realidad no lo hace. Se calcula dividiendo el total de verdaderos negativos (VN) entre la suma de estos y los falsos positivos (FP).

$$SPE = \frac{VN}{VN + FP} \quad (17)$$

5.7.3 Sensibilidad

Indica la capacidad del algoritmo para asignar el valor verdadero de la clase al caso en cuestión; en otras palabras, indica la proporción de clases correctamente identificadas. Es el resultado del cociente entre los verdaderos positivos (VP) y la suma de estos con los falsos negativos (FN):

$$SEN = \frac{VP}{VP + FN} \quad (18)$$

En otras palabras, se dice que la sensibilidad es proporción de verdaderos positivos (VP) y la especificidad la de verdaderos negativos (VN).

5.7.4 Exactitud

La exactitud (ACC, por su nombre en inglés) indica la capacidad del algoritmo para clasificar correctamente; es decir, si el algoritmo puede o no asignar acertadamente la clase al caso en cuestión. Se calcula dividiendo los casos correctamente bien clasificados entre el total de los casos.

$$ACC = \frac{VP + VN}{VP + VN + FP + FN} \quad (19)$$

5.7.5 Precisión

La precisión indica la dispersión de los valores obtenidos; es decir, tiene que ver con la repetitividad de la clasificación. En otras palabras, suponiendo que la clasificación del caso en cuestión fuera errónea, la precisión mide la capacidad del algoritmo para repetir esa misma clasificación.

$$PPR = \frac{VP}{VP + FP} \quad (20)$$

La diferencia entre exactitud y precisión, se puede observar en la imagen de la Figura 5.4.

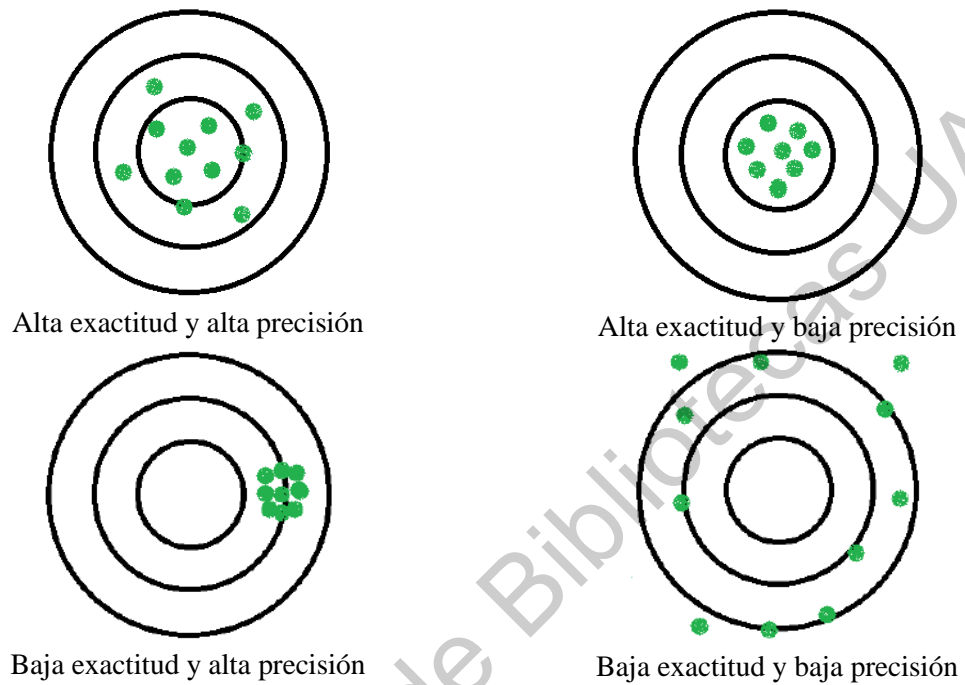


Figura 5.4. Diferencia entre precisión y exactitud.

6 Metodología

La metodología realizada en este proyecto para alcanzar los objetivos propuestos se ilustra en la Figura 6.1.

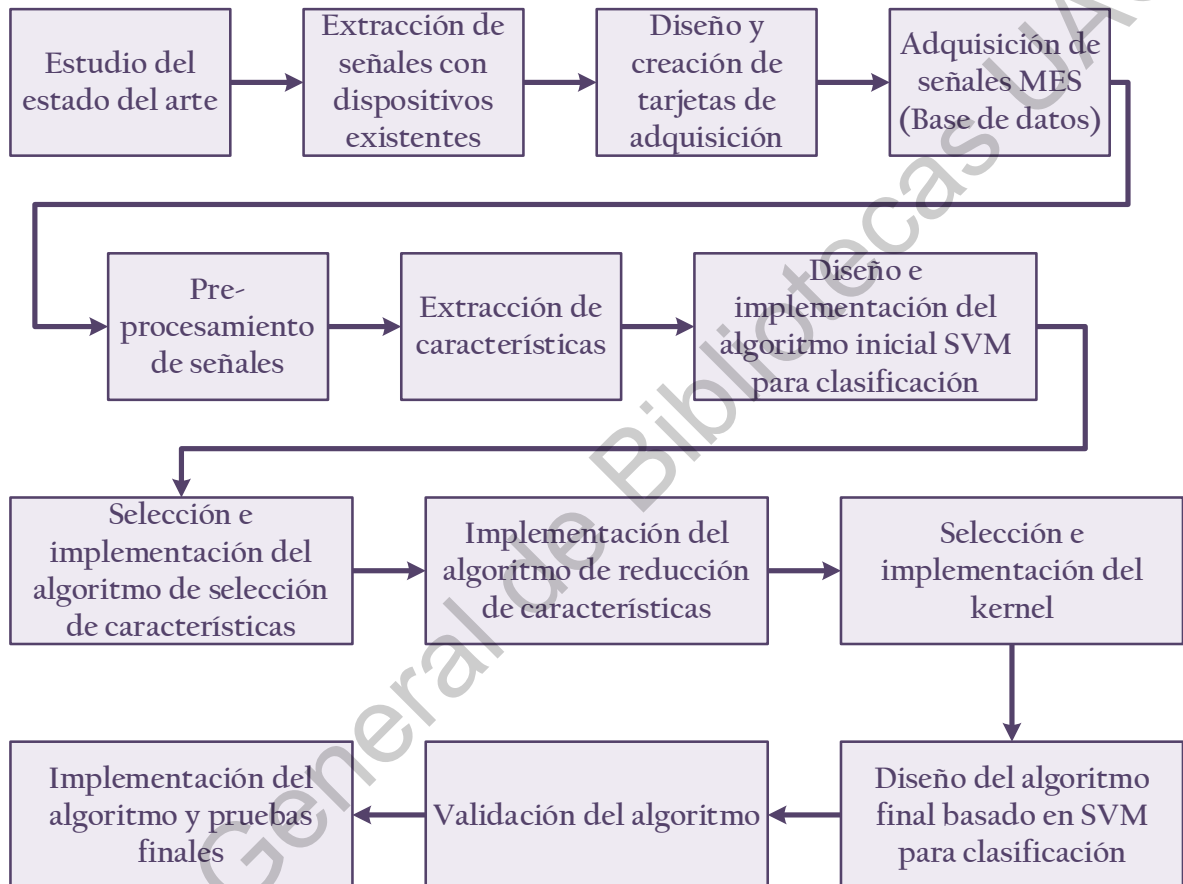


Figura 6.1. Diagrama general de tesis.

La primera etapa consistió en el estudio del estado del arte, donde se revisaron los algoritmos para clasificación con base en el reconocimiento de patrones, además de las herramientas implementadas para su mejora. Por otra parte, se realizó una búsqueda de bases de datos de señales mioeléctricas de la sección transtibial, sin embargo; fue difícil localizar alguna con suficiente información para realizar más de 6 pruebas, por lo que se optó por la opción de crear una base de datos propia, lo que llevó a una segunda etapa del proyecto;

donde se estudiaron e incluso adquirieron algunos de los dispositivos comerciales para la adquisición de señales MES; finalmente, se optó por diseñar las tarjetas de adquisición, para poder recopilar 8 canales al mismo tiempo y enviar los datos vía bluetooth. Después de la manufactura de la tarjeta, se procedió a realizar la adquisición de señales.

La tercera etapa del proyecto consistió en el pre-procesamiento de datos, donde se filtraron y segmentaron los datos, con los cuales se hizo la extracción de características. Con la información recopilada en el estado del arte, se diseñó un algoritmo SVM que permitiera clasificar las señales. En la cuarta etapa se implementaron diferentes algoritmos de selección (Relief y SBMLR), y se seleccionó el que arrojó los mejores resultados en cuanto a exactitud y precisión. Posteriormente se implementó un algoritmo PCA para reducción de características. En la siguiente etapa se experimentó con diferentes tipos de kernel, y al igual que en la etapa 4, se seleccionó el que arrojó los mejores resultados en cuanto a exactitud. Después se obtuvo el algoritmo con base en SVM. Para validar el algoritmo se utilizó la misma base de datos que Sapsanis *et al.*, (2013) en su trabajo.

Finalmente se implementó el algoritmo en la clasificación de diferentes movimientos de pierna; dicho algoritmo podría ser utilizado para el control de prótesis transtibiales.

En las siguientes sub-secciones se detallan los resultados obtenidos en cada uno de los bloques de la metodología del proyecto.

6.1 Tarjeta de adquisición de señales

La tarjeta de adquisición de señales consta de varias etapas, que se conectan a una fuente bipolar de 5 V, con conexión a tierra física (GND). La primera etapa de la tarjeta es la de adquisición de señal, y es la que se conecta directamente al cable para electrodos. Se describe en la Figura 6.2; y consta de los siguientes elementos:

- Dispositivo macho para el cable para electrodos.
- Resistencias de varias denominaciones.
- Capacitores de varias denominaciones.
- Diodos IN4148.
- Amplificador instrumental INA114.

- Punta de prueba (TP1).




Figura 6.2. Adquisición de señal mioeléctrica.

Después de la etapa de adquisición, se realizaron una etapa de filtrado y dos etapas de amplificación de la señal (Figura 6.3); la primera para eliminar el ruido de la línea, de 60 Hz. Se realizaron dos etapas de amplificación debido a que la señal se encuentra en el rango de los mV y se necesita aumentar alrededor de 1000 veces. Estas etapas constan de los siguientes elementos:

- Resistencias de varios valores.
- Resistencias variables.
- Capacitores de diferentes denominaciones.
- Amplificador operacional TL084.
- Fuente bipolar de 5 V.
- Puntas de prueba (TP2 y TP3).

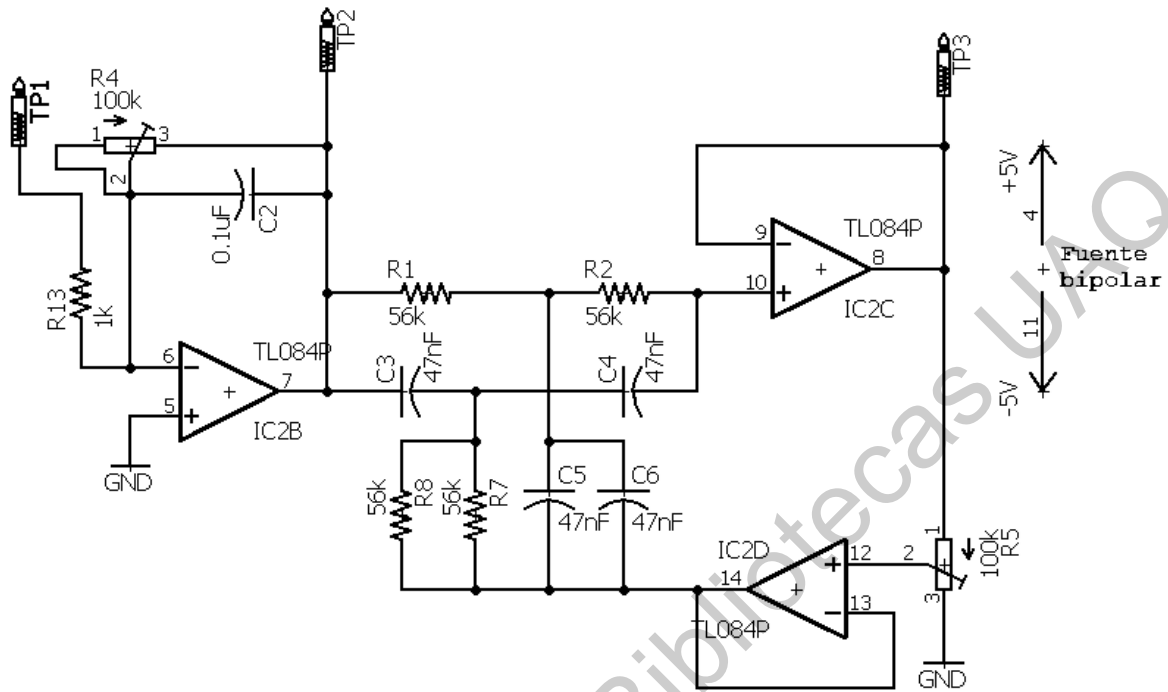


Figura 6.3. Etapas de filtrado y doble amplificación de la señal.

Finalmente, se utilizó otro amplificador operacional para mover la referencia de voltaje de 0 V a 2.5 V, como se ve en la Figura 6.4. Esto se hace debido a que la señal tiene valores negativos y el ADC tiene un rango de 0 a 5 V. Mover la referencia a la mitad, ayuda a que el ADC pueda hacer la conversión de forma correcta. Esta etapa es relativamente sencilla y consta de los siguientes elementos:

- Resistencias de varias denominaciones.
- Resistencia variable.
- Fuente de alimentación.
- Amplificador operacional TL084.
- Puntas de prueba (TP3 y TP4).
- Pines para la salida de la señal, tierra y alimentación.

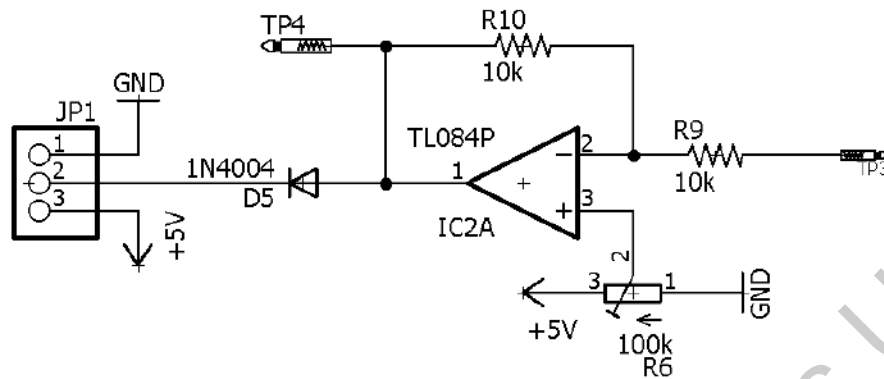


Figura 6.4. Etapa de movimiento de referencia de la señal.

Para el desarrollo de los experimentos, se hicieron cuatro tarjetas iguales, el electrodo utilizado para las pruebas fue de la marca Kendal MediTrace 200 (Electrodo circular bipolar Ag/AgCl con un diámetro de 10 mm y con un gel adhesivo conductor) y se muestra en la Figura 6.5. Los electrodos se adquirieron en un paquete de 100, ya que para cada sujeto de prueba se utilizaron nueve.



Figura 6.5. Electrodo Kendal MediTrace 200.

El cable utilizado para los electrodos es de tres líneas, terminal positiva, terminal negativa y tierra física (Figura 6.6); se utilizaron cuatro cables para los experimentos; para obtener 4 señales diferentes (llamados canales); sin embargo, como la tierra es común en las cuatro tarjetas de adquisición, sólo se adhirió una terminal de tierra física durante el experimento y el resto de ellas se dejaron sin conectar; aunque bloqueadas para evitar lectura de ruido.



Figura 6.6. Cables para electrodos.

Para el envío de información a la computadora, se realizó una pequeña tarjeta que utilizó un dispositivo Bluetooth, en un HC-05, con un BaudRate modificado a 230400, y un micro-controlador STM32F103C8, con un ADC de 12-bits, enviando paquetes de 2 bytes a la PC en formato ASCII. Además, se agregaron pines para la recepción de la señal de salida de cada una de las tarjetas de adquisición y algunos capacitores para eliminar ruido proveniente de la línea. El pseudo-código utilizado para el envío de la información es el siguiente:

- Inicializar la variable *micros* con un valor de cero.
- Inicio del proceso.
- Asignación del BaudRate a 230400.
- Asignación a un pin como salida.
- Comienzo de un ciclo.
- Evaluación de la variable, para repetir el proceso con una frecuencia de 1 kHz.
- Declaración de una variable, tipo vector *entera sin signo*, de dimensión cuatro (*adcval*).
- Asignación de cada canal analógico al vector declarado en el punto anterior.
- Declaración de una variable *char sin signo* de dimensión 2, (*buffy*).
- Ciclo *for* de cuatro tiempos, con las siguientes líneas:

- `buffy[0] = (unsigned char)((adcval[i] & 0xFF00) >> 8);`
- `buffy[1] = (unsigned char)(adcval[i] & 0x00FF);`
- Asignación al pin de escritura del puerto serial, la variable `buffy`, 2
- Fin del ciclo *for*.
- `buffy[0] = 0x0D;`
- Asignación al pin de escritura del puerto serial, la variable `buffy`, 1.
- Fin del ciclo.
- Fin del proceso.

Las cuatro tarjetas se juntaron en una sola placa, a cada una de las tarjetas se le colocó un inversor de voltaje, para poder alimentarlas con la misma fuente. Para la fuente se usó una batería, así que también se agregó un dispositivo para cargarla y otro para regular la salida. Por otra parte, se agregó un interruptor para encender y apagar los dispositivos de adquisición. La tarjeta final se muestra en la Figura 6.7.




Figura 6.7. Tarjeta de adquisición de señales mioeléctricas.

6.2 Base de datos

Con las señales adquiridas en archivos de texto, se formó una base de datos, con formato *.mat, con ayuda de MATLAB, donde:

1. Abrir en diferentes variables cada uno de los archivos de cada movimiento de cada repetición.
2. Importar datos de cada variable creada en el paso 1.
3. Juntar el texto de los datos importados en el paso 2.
4. Búsqueda del patrón insertado entre cada medición de los canales analógicos, “ODOA”.
5. Formar vectores de cada canal partiendo del patrón para cada repetición.
6. Conversión de formato hexadecimal a decimal.
7. Unión de cada repetición en una matriz del mismo movimiento.
8. Guardar los movimientos en cada archivo por sujeto.

Para realizar la base de datos, se hicieron pruebas con 8 sujetos, que dijeron encontrarse en buen estado de salud; sin sobre peso y sin amputaciones; cuatro hombres y cuatro mujeres, a los que se les colocaron 9 electrodos en la pierna derecha, dos por cada uno de los cuatro músculos considerados y uno más para la tierra, la distancia de separación entre ellos fue de 2.5 cm, distancia óptima para poder tener la mayor cantidad de información (Sacco et al., 2009). La posición de dos pares de electrodos se colocó según SENIAM (2009); con respecto a las otras dos, Sacco et al., (2009) señala que existe otra posición para obtener una mejor calidad de la señal. Las posiciones de los cuatro pares de electrodos y el de tierra física se describen a continuación:

1. *Vastus lateralis* (VL), el electrodo se colocó al 66% de la longitud del músculo en la línea desde la espina iliaca superior al lateral de la rótula.
2. *Tibialis anterior* (TA), es al 47.5% en la línea entre la punta del peroné y la puntal del maléolo interno.

3. *Gastrocnemius medialis* (GM), donde la posición idónea es al 38% de la longitud del músculo desde el lado medial de la cavidad poplíteica hasta el lado medial de la inserción del tendón de Aquiles, partiendo del tendón de Aquiles.
4. *Biceps femoris* (BF), a la mitad de la posición en la línea entre la tuberosidad isquiática y el epicóndilo lateral de la tibia.
5. La terminal de tierra se colocó en el costado interno de la rodilla.

Para los experimentos, se realizaron 6 diferentes movimientos de pie. El procedimiento para realizar el experimento fue de la siguiente manera:

- los sujetos se encontraban sentados, con una posición de relajación donde no se ejecutaba ningún movimiento;
- después, realizaron el movimiento y sostuvieron esa posición durante cinco segundos;
- finalmente regresaron a la posición de relajación.

Cada movimiento se realizó un total de 20 veces, con intervalos de 25 segundos. Los movimientos ejecutados fueron seis: levantar la punta del pie (LP), levantar el talón (LT), mover la punta hacia la derecha (PD), mover la punta a la izquierda (PI), apoyar la punta sin levantar el talón (AP) y apoyar el talón sin levantar la punta (AT); el estado de relajación (RR) también fue considerado, teniendo un total de 7 movimientos a clasificar. Las señales fueron muestreadas con una frecuencia de 1 kHz. El diagrama general del experimento se puede observar en la Figura 6.8; el cual consiste en extraer las señales con ayuda del circuito integrado INA114, que fue diseñado para éste propósito, después una etapa de amplificación con un factor aproximado de 1000; después un filtro analógico Notch, para eliminar las frecuencias de 60 Hz, finalmente un ADC para poder tener las señales en formato digital y guardarlas en la PC.

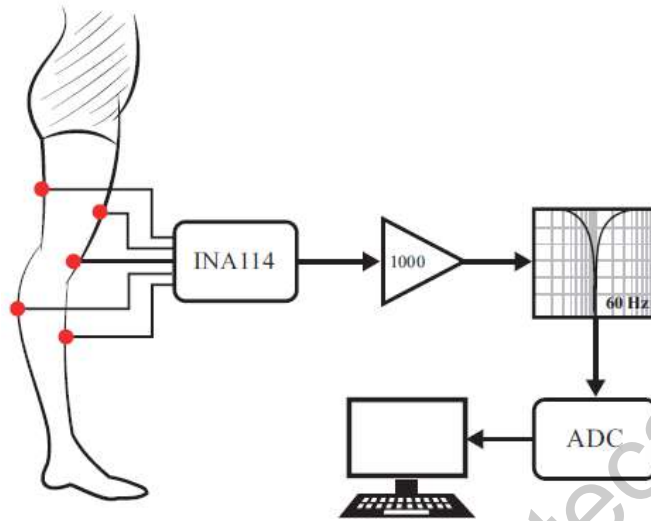


Figura 6.8. Diagrama general del proceso de adquisición de señales.

El análisis de las señales, su procesamiento y clasificación fue realizado en el software de MATLAB®. Las siguientes subsecciones describen el pre-procesamiento de las señales, análisis y algoritmo de clasificación.

6.3 Filtros

Además del filtro analógico Notch, se implementaron filtros digitales, para remover el resto de las frecuencias en las que se encuentra la mayor cantidad de ruido.

Los filtros implementados en software, son dos diferentes, el primero se encarga de suprimir el ruido de la línea que no es eliminado con el filtro analógico de las tarjetas y el segundo elimina el ruido en las frecuencias superiores a 500 Hz y en las inferiores a 10 Hz (Ibrahim-Aly *et al.*, 2018; Tavakoli *et al.*, 2018).

6.3.1 Filtro Notch

El filtro se utilizó para remover el ruido que no fue suprimido por el filtro analógico; el parámetro de espesor (w) utilizado fue de “0.8”; las ecuaciones para el cálculo de ceros y polos del filtro, ecuación (21) y (22 respectivamente; donde f_s corresponde a la frecuencia de muestreo (1 kHz).

$$ceros = e^{(\pi(f_s)i)^{1/2}} + e^{(-\pi(f_s)i)^{1/2}} \quad (21)$$

$$polos = (1-w)*ceros \quad (22)$$

Después, con ayuda de la función *poly*, se calcularon los polinomios correspondientes para después realizar el filtrado con la función *filter*. En la Figura 6.9 se muestran el diagrama de ceros y polos; y en la Figura 6.10 el diagrama de frecuencias, ambas, del filtro Notch. En éstas se puede apreciar que la frecuencia de corte utilizada fue de 60 Hz, al ser el punto de mayor atenuación; es decir, donde la magnitud es más pequeña o donde se hace el cambio de fase. También se puede observar que, en las frecuencias cercanas a ese punto, se hace una atenuación gradual.




Figura 6.9. Ceros y polos del filtro Notch.

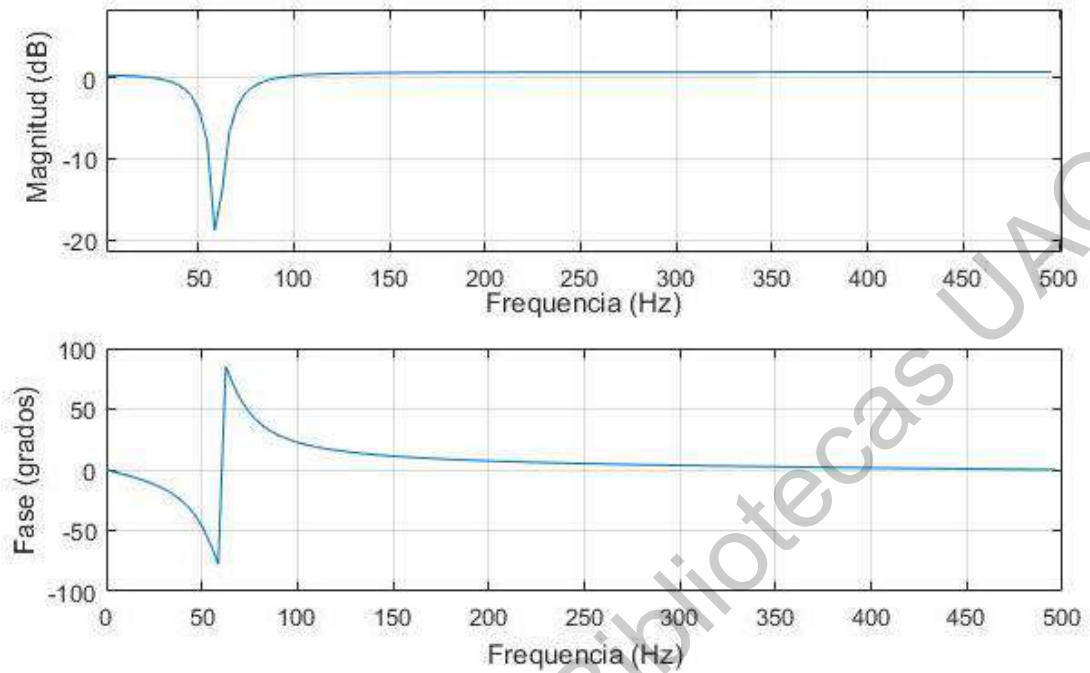


Figura 6.10. Diagrama de frecuencias del filtro Notch.

6.3.2 Filtro PasaBanda

El filtro pasa banda se utilizó para remover las frecuencias menores a 10 Hz y las mayores a 500 Hz. Los parámetros que utiliza MATLAB® para el filtro se ilustran en la Figura 6.11.




Figura 6.11. Parámetros de diseño del filtro PasaBanda.

De la Figura 6.11, se definen:

- $W_p = [\omega_1, \omega_2]$
- $W_s = [\omega_3, \omega_4]$

Los parámetros utilizados para el diseño del filtro elíptico en MATLAB® son:

- $W_p = 2 * [12 \ 498] / f_s$
- $W_s = 2 * [8 \ 502] / f_s$
- $R_p = 11$
- $R_s = 51$

Para obtener el orden mínimo del filtro se utilizó la función *ellipord* y para los coeficientes del filtro *ellip*; finalmente la señal volvió a filtrarse con la función *filter*.

En la Figura 6.12 se muestra en la parte superior una señal sin filtro digital, y en la parte inferior, una con filtro digital.

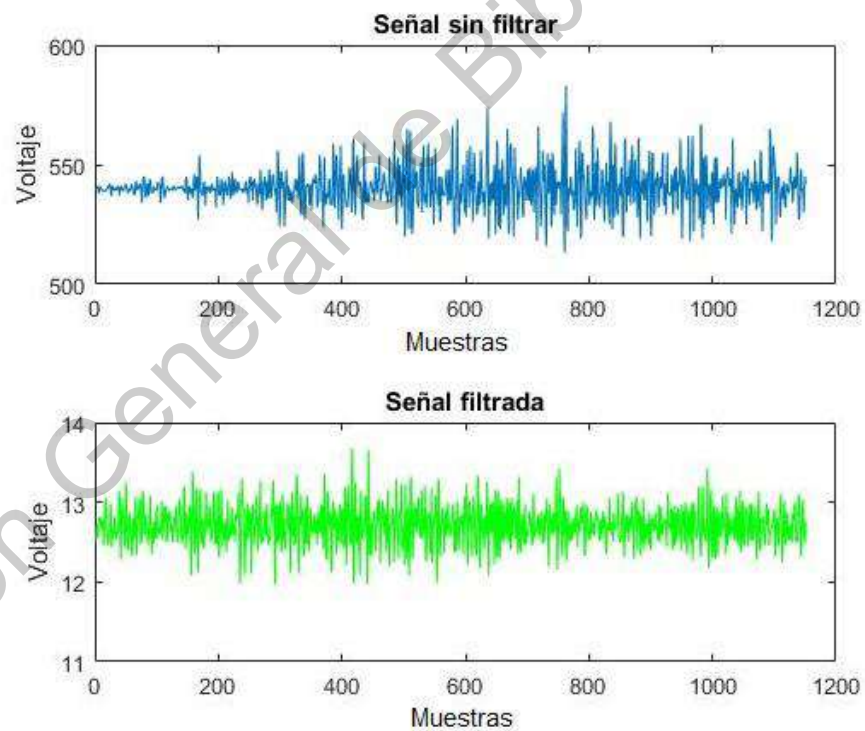


Figura 6.12. Muestra de una señal filtrada y una sin filtrar.

6.4 Extracción de características

Como ya se mencionó antes, las características utilizadas para la descripción de las señales mioeléctricas fueron MAV, ZC, SSC y WL. Estas cuatro características conforman la matriz de características; para cada señal de cada movimiento de cada canal. La matriz resultante 16 columnas (n). El total de las 20 muestras se dividió en dos, las primeras 10 repeticiones se utilizaron para el entrenamiento del algoritmo de clasificación, y las 10 restantes se usaron para las pruebas del algoritmo; lo que resulta en un total de 70 filas (m) para la matriz de características. Se describió de la siguiente forma, donde la expresión (C1)-(C4) indica que se colocó cada uno de los cuatro canales del mismo movimiento:

[MAV_LP(C1)-(C4)	ZC_LP(C1)-(C4)	WL_LP(C1)-(C4)	SSC_LP(C1)-(C4);
	MAV_LT(C1)-(C4)	ZC_LT(C1)-(C4)	WL_LT(C1)-(C4)	SSC_LT(C1)-(C4);
	MAV_PD(C1)-(C4)	ZC_PD(C1)-(C4)	WL_PD(C1)-(C4)	SSC_PD(C1)-(C4);
	MAV_PI(C1)-(C4)	ZC_PI(C1)-(C4)	WL_PI(C1)-(C4)	SSC_PI(C1)-(C4);
	MAV_AT(C1)-(C4)	ZC_AT(C1)-(C4)	WL_AT(C1)-(C4)	SSC_AT(C1)-(C4);
	MAV_AP(C1)-(C4)	ZC_AP(C1)-(C4)	WL_AP(C1)-(C4)	SSC_AP(C1)-(C4);
	MAV_RR(C1)-(C4)	ZC_RR(C1)-(C4)	WL_RR(C1)-(C4)	SSC_RR(C1)-(C4)]

6.5 Selección de características

Para implementar los algoritmos de selección de características se usaron los softwares WEKA versión 3.6.11 y SPIDER versión 1.71. El software de minería de datos SPIDER, es ampliamente utilizado y contiene las implementaciones de varios algoritmos de agrupamiento populares. Además, es un entorno orientado a objetos para MATLAB, desarrollado por Weston J. et al. (Weston *et al.*). La máquina WEKA es un conjunto de algoritmos de aprendizaje automático para tareas de minería de datos, fue desarrollado por la Universidad de Waikato y se distribuye gratuitamente bajo la licencia GNU-GPL (Eibe *et al.*, 2016).

Los algoritmos de selección de funciones de Relieve y SBMLR se tomaron del Repositorio de Selección de Características de ASU (Li *et al.*, 2017); el primero se desarrolló basado en Liu y Motoda, (2008) y el segundo se basó en Cawley *et al.*, (2007).

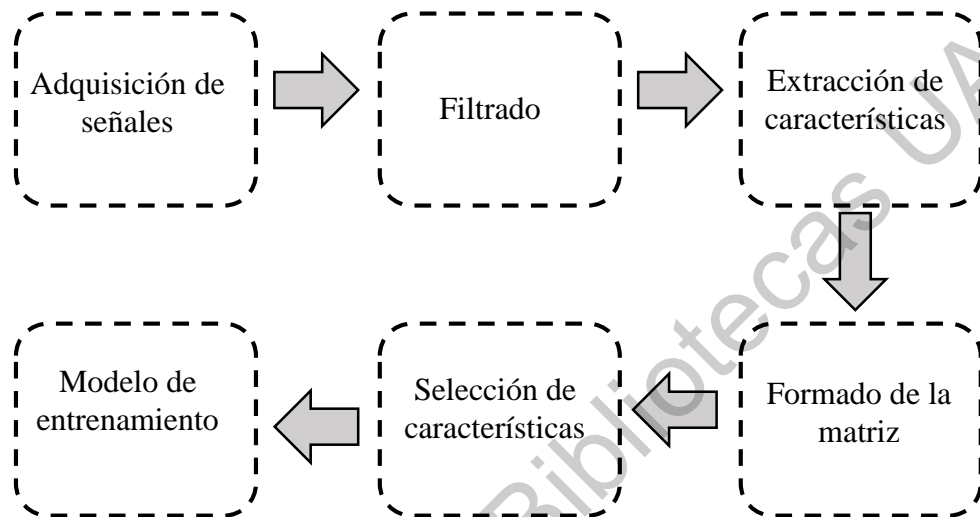


Figura 6.13. Diagrama a bloques del proceso de entrenamiento de la matriz de clasificación.

La Figura 6.13 abrevia el proceso que siguen las señales hasta que se obtiene la matriz que resulta del entrenamiento del SVM, a partir de la adquisición de señales. En un primer paso, en la sección de selección de características, se implementó el algoritmo SBMLR; posteriormente las pruebas se hicieron utilizando el de Relieve.

Después de las implementaciones, se realizó una nueva selección de características para la mayoría de los sujetos de prueba. De esta manera, buscamos considerar las características más relevantes. Finalmente, se repitió el proceso, omitiendo las características no seleccionadas por los algoritmos de selección de características.

Subsecuentemente, el proceso de selección de características, se desarrolló un proceso de entrenamiento con clasificador SVM, en el cual, primero se obtuvo la exactitud con la matriz completa, sin *bloque de selección de características*, segundo después de aplicar la técnica SBMLR y luego el método de relieve, fue lo mismo para el proceso de prueba.

Resumiendo, la primera matriz de características fue ensamblada utilizando MAV, ZC, SSC y WL, luego se obtuvo su modelo de entrenamiento SVM. La segunda matriz de características se formó aplicando la técnica SBMLR a la primera y luego, la tercera matriz de características se derivó de la aplicación del método de relieve a la primera. Después de eso, el modelo de entrenamiento SVM fue obtenido de las dos últimas matrices de características. Esto completa el proceso de entrenamiento; posteriormente, se calculó la exactitud de la clasificación para cada matriz de características en el proceso de prueba.

6.6 Análisis de Componentes Principales

Después, a la matriz de características (mCA) de dimensión $m \times n$, se le hizo un análisis de componentes principales; a continuación, se describe en pseudo-código el algoritmo descrito para realizarlo:

-
- mCOV = Matriz de covarianzas de mCA (dimensión $c \times c$)
 - vEI = Eigen-vectores de mCOV
 - dEI = Eigen-values de vEI
 - mCOM = dEI multiplicada por una matriz identidad de dimensión c
 - suma = Suma de los componentes de dEI
 - mPCA = [sqrt(mCOM); mCOM/suma]
-

Del algoritmo descrito, se tienen dos valores importantes; vEI que es una matriz con los eigen-vectores de la matriz de covarianzas, de dimensión $c \times c$, y mPCA que es una matriz de dimensión $2 \times c$. La segunda fila de la matriz mPCA se utiliza para conocer la relevancia, o importancia de cada uno de los eigen-vectores de la matriz vEI; quedan ordenados del menos al más importante, en una escala de 0 a 1.

Finalmente, se hace una reducción de dimensión a la matriz vEI, considerando sólo el 98% de la información, con el menor número de vectores, por lo que se sólo se tomaron en cuenta aquellos que contenían la mayor cantidad de información. Esto se hace para reducir la dimensionalidad de la matriz de características. Algunos autores como Guo *et al.*, (2019)

sugieren que con tomar los tres principales componentes es necesario; sin embargo por el tipo de varianza que presentan las señales; tres componentes no son suficientes.

Muñoz *et al.*, (2008) señala que un 80 0 90% podría ser una buena proporción de la varianza, alcanzada por incluso un solo componente; sin embargo, pueden existir más componentes que sean adecuados para explicar la estructura de las variables.

Akhmadeev *et al.*, (2017) indican que retener el 97% del total de la varianza es suficiente; mientras que Azar *et al.*, (2014) y Waris *et al.*, (2018) mencionan que el 99% es más adecuado. En este trabajo se realizaron algunas pruebas con 97%, 98%, 99% y sin eliminar vectores. Se encontró que con 98% de la varianza con los vectores principales, los resultados en la clasificación son mejores que con 97%; y no se encontraron diferencias significativas al aumentar a 99%; sin embargo, si aumenta considerablemente el número de vectores necesarios para alcanzarlo. De esta forma se busca garantizar una exactitud en la clasificación dentro del 5% de la mejor precisión lograda, como sugieren Matsumura *et al.*, (2006) y, Camargo y Young, (2019).

En las siguientes líneas se describe con pseudo-código utilizado para la reducción de la dimensionalidad a través de PCA:

```
- suma = 0
- i = c
- while (suma < 0.98)
  o suma = suma + mPCA(2,i)
  o restar 1 a i.
- end
- xPCA = matriz reducida a i columnas de vEI, comenzando por el último vector
- mtrain = mCA * xPCA
```

La dimensión final de la matriz de entrenamiento (mtrain) es de m, por el número de columnas que suman el 98% de la información (p), es decir, 70Xp.

6.7 Algoritmo de clasificación (SVMs)

El algoritmo de clasificación, como se describió anteriormente, son las máquinas de soporte de vectores. Para la implementación de este algoritmo se utilizó una librería desarrollada para MATLAB® por Chih-Chung Chang and Chih-Jen Lin, llamada LIBSVM, versión 3.22.

La librería cuenta con la opción de utilizar un “kernel”, los disponibles son:

- Lineal
- Cuadrático
- Polinomial
- Sigmoide

Para las pruebas se utilizó el tipo lineal, ya que es uno de los más recomendados en la literatura para señales EMG, sin embargo; más adelante se hicieron pruebas para analizar si es el que más conviene al trabajo.

Por otra parte, la librería también permite seleccionar el método para encontrar el hiper-plano: a) optimización mínima secuencial, b) programación cuadrática y c) mínimos cuadráticos. La opción seleccionada para la clasificación fue la de optimización secuencial.

El código implementado en la librería se describe a continuación:

```
-----  
- model = svmtrain(e, mtrain, '-s 0 -t 0 -c 1');  
- w = model.SVs' * model.sv_coef;  
- b = -model.rho;  
- if (model.Label(1) == -1)  
-     w = -w;  
-     b = -b;  
- end  
-----
```

Donde “e” es un vector de etiquetas de las muestras, para este caso es un vector numerado con 10 números ‘1’, 10 números ‘2’ y así sucesivamente hasta 10 números ‘7’.

7 Resultados y discusión

7.1 Comparativa de canales

Para definir el tamaño de ventana óptimo para hacer el análisis de la muestra, se realizaron experimentos comparativos con ventanas de número de muestras (No.) 250, 500 y 1000. Además, se comparó el resultado obtenido de la clasificación partiendo de uno hasta cuatro canales. La exactitud obtenida en la clasificación con los canales individuales se observa en la Tabla 7-1, en la fila inferior se muestra el promedio por cada grupo de muestras en cada canal. En la tabla se observa que, en promedio, el canal VL tiene el mejor comportamiento, mientras que el canal TA exhibe el promedio más bajo en los tres tipos de ventana analizados; el promedio al considerar las tres cantidades de muestras del canal VL es de 80.1% y el del canal TA de 72.3%.

Tabla 7-1. Exactitud obtenida por sujeto con cada canal.

Canal	TA			GM			BF			VL			
	No.	250	500	1000	250	500	1000	250	500	1000	250	500	1000
Mujer 1		71.4%	70.0%	74.3%	75.7%	80.0%	71.4%	65.7%	54.3%	64.3%	72.9%	65.7%	75.7%
Mujer 2		72.9%	67.1%	72.9%	55.7%	62.9%	70.0%	61.4%	65.7%	70.0%	85.7%	78.6%	84.3%
Mujer 3		64.3%	70.0%	64.3%	71.4%	81.4%	78.6%	88.6%	87.1%	82.9%	65.7%	75.7%	78.6%
Mujer 4		54.3%	72.9%	72.9%	85.7%	85.7%	91.4%	74.3%	74.3%	85.7%	87.1%	87.1%	92.9%
Hombre 1		82.9%	88.6%	85.7%	84.3%	87.1%	88.6%	85.7%	87.1%	91.4%	78.6%	84.3%	88.6%
Hombre 2		52.9%	55.7%	67.1%	67.1%	65.7%	71.4%	77.1%	88.6%	78.6%	72.9%	80.0%	80.0%
Hombre 3		72.9%	80.0%	82.9%	82.9%	88.6%	88.6%	74.3%	84.3%	85.7%	90.0%	91.4%	95.7%
Hombre 4		78.6%	85.7%	82.9%	78.6%	88.6%	82.9%	77.1%	78.6%	84.3%	74.3%	81.4%	78.6%
Promedio		69.1%	73.7%	74.0%	74.6%	79.4%	80.0%	75.1%	73.7%	78.9%	78.0%	78.3%	84.0%
Promedio total		72.3%			78%			75.9%			80.1%		

Por otra parte, la exactitud obtenida de la combinación de dos canales se muestra en las Tablas Tabla 7-2 y Tabla 7-3; donde la penúltima fila corresponde al promedio de los resultados obtenidos por cada cantidad de muestras (Prom) y la última el promedio de estos (P Tot). En ellas se puede observar que la combinación de los canales GM y VL exhibe la exactitud con el mejor promedio, con 90.8%, mientras que los canales TA y VL tienen la exactitud con el peor promedio, de 83.3%. Es fácil notar que el mejor promedio incluye el canal con el mejor desempeño; mientras que el peor promedio incluye al músculo con el resultado más bajo; además del de mejor resultado, lo que nos indica que hace más daño el canal con el peor resultado comparado con el bien del canal con el mejor desempeño.

Tabla 7-2. Exactitud obtenida por sujeto combinando dos canales, parte 1.

Canales	TA y GM			TA y BF			TA y VL		
	250	500	1000	250	500	1000	250	500	1000
M 1	91.4%	92.9%	87.1%	85.7%	87.1%	87.1%	74.3%	72.9%	75.7%
M 2	81.4%	78.6%	81.4%	72.9%	75.7%	80.0%	84.3%	82.9%	81.4%
M 3	80.0%	81.4%	85.7%	88.6%	88.6%	91.4%	70.0%	75.7%	81.4%
M 4	85.7%	87.1%	88.6%	81.4%	82.9%	84.3%	85.7%	91.4%	95.7%
H 1	90.0%	95.7%	97.1%	91.4%	97.1%	98.6%	88.6%	94.3%	95.7%
H 2	84.3%	74.3%	87.1%	87.1%	92.9%	97.1%	72.9%	85.7%	77.1%
H 3	87.1%	88.6%	90.0%	81.4%	81.4%	87.1%	92.9%	94.3%	98.6%
H 4	92.9%	97.1%	92.9%	90.0%	95.7%	95.7%	82.9%	92.9%	91.4%
Prom	85.7%	87.1%	88.0%	84.0%	86.3%	88.3%	80.6%	83.4%	86.0%
P Tot	86.9%			86.2%			83.3%		

Tabla 7-3. Exactitud obtenida por sujeto combinando dos canales, parte 2.

Canales	GM y BF			GM y VL			BF y VL		
	250	500	1000	250	500	1000	250	500	1000
M 1	81.4%	75.7%	77.1%	92.9%	88.6%	92.9%	80.0%	77.1%	84.3%
M 2	72.9%	72.9%	81.4%	87.1%	84.3%	88.6%	85.7%	80.0%	82.9%
M 3	84.3%	84.3%	91.4%	82.9%	85.7%	88.6%	91.4%	94.3%	94.3%
M 4	87.1%	84.3%	88.6%	90.0%	95.7%	97.1%	90.0%	92.9%	92.9%
H 1	90.0%	90.0%	97.1%	95.7%	97.1%	94.3%	91.4%	95.7%	97.1%
H 2	84.3%	87.1%	92.9%	80.0%	82.9%	81.4%	88.6%	95.7%	84.3%
H 3	81.4%	90.0%	90.0%	92.9%	97.1%	97.1%	87.1%	92.9%	95.7%
H 4	90.0%	94.3%	95.7%	81.4%	92.9%	90.0%	87.1%	87.1%	88.6%
Prom	83.1%	81.4%	87.1%	89.7%	90.3%	92.3%	87.7%	88.0%	90.3%
P Tot	83.9%			90.8%			88.7%		

Al combinar tres canales, los resultados obtenidos comparados con la exactitud de dos canales, se muestran similares. La combinación con el mejor desempeño es la que contiene los canales GM, BF y VL, ya que omite el canal con el peor desempeño que es TA, y es de 92.4%; mientras que la combinación con el peor desempeño es la que omite la del mejor resultado, es decir, aquella que no contiene el canal VL; y que, si contiene TA, el promedio de exactitud obtenido es de 88.5%; significativamente más baja que la omitida con los canales que presentan la mejor señal.

Tabla 7-4. Exactitud obtenida por sujeto al combinar tres canales.

Canal	TA, GM y BF			TA, GM y VL			GM, BF y VL		
	250	500	1000	250	500	1000	250	500	1000
M 1	88.6%	92.9%	90.0%	88.6%	92.9%	90.0%	88.6%	92.9%	90.0%
M 2	78.6%	78.6%	87.1%	84.3%	84.3%	88.6%	90.0%	84.3%	85.7%
M 3	84.3%	88.6%	91.4%	84.3%	90.0%	92.9%	90.0%	95.7%	95.7%
M 4	84.3%	84.3%	88.6%	91.4%	95.7%	98.6%	92.9%	94.3%	97.1%
H 1	92.9%	98.6%	98.6%	90.0%	98.6%	97.1%	94.3%	97.1%	97.1%
H 2	92.9%	94.3%	95.7%	81.4%	82.9%	94.3%	90.0%	91.4%	98.6%
H 3	85.7%	90.0%	90.0%	95.7%	95.7%	97.1%	90.0%	97.1%	97.1%
H 4	91.4%	97.1%	98.6%	87.1%	100.0%	97.1%	91.4%	92.9%	95.7%
Prom	85.7%	88.6%	91.1%	87.7%	92.3%	93.4%	91.1%	92.9%	93.1%
P Tot	88.5%			91.1%			92.4%		

Finalmente, en la Tabla 7-5 se muestra la combinación de los cuatro canales, con un promedio de 92%; realizando una comparación con el desempeño de tres canales, se obtuvo un promedio ligeramente inferior, de 0.4%, si se observa el mejor caso. De la misma forma, al comparar con dos canales en el mejor caso, la diferencia es de 1.6%. Estos resultados indican que es posible obtener buenos resultados desde dos canales; sin embargo, la variación todavía es bastante, depende principalmente del individuo que se observe, mientras que, al considerar los cuatro canales, los resultados fueron más consistentes.

Tabla 7-5. Exactitud obtenida por sujeto, utilizando cuatro canales.

Canales	TA, GM, BF y VL			
	No.	250	500	1000
Mujer 1		88.6%	91.4%	90.0%
Mujer 2		81.4%	81.4%	87.1%
Mujer 3		90.0%	95.7%	95.7%
Mujer 4		91.4%	94.3%	98.6%
Hombre 1		95.7%	100.0%	98.6%
Hombre 2		92.9%	95.7%	100.0%
Hombre 3		97.1%	97.1%	98.6%
Hombre 4		94.3%	100.0%	97.1%
Promedio		89.4%	92.6%	94.0%
P Tot		92%		

7.2 Selectiva de características

Los vectores seleccionados después de aplicar el método SMBLR se muestran en la Tabla 7-6, mientras que los seleccionados por Relief se encuentran en la Tabla 7-7. En estas tablas, cada columna representa los resultados obtenidos por un solo canal para cada individuo.

Tabla 7-6. Selección de características para cada sujeto con SMBLR utilizando MAV, ZC, SSC y WL.

Sujeto	MAV				ZC				SSC				WL			
	C1	C2	C3	C4	C1	C2	C3	C4	C1	C2	C3	C4	C1	C2	C3	C4
M 1					X	X	X	X		X		X	X	X	X	
M 2					X	X	X	X	X			X	X		X	X
M 3						X	X	X	X	X		X	X		X	X
M 4					X	X	X	X	X	X	X	X			X	X
H 1					X	X	X	X	X	X	X	X		X	X	
H 2					X	X	X	X	X	X	X	X	X	X		
H 3					X	X	X	X	X	X	X	X	X			X
H 4					X	X	X	X	X	X	X	X	X			X

Tabla 7-7. Selección de características para cada sujeto con el algoritmo Relief utilizando MAV, ZC, SSC y WL.

Sujeto	MAV				ZC				SSC				WL			
	C1	C2	C3	C4	C1	C2	C3	C4	C1	C2	C3	C4	C1	C2	C3	C4
M 1		X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
M 2			X	X	X	X	X	X	X	X	X	X	X	X	X	X
M 3		X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
M 4					X	X	X	X	X	X	X	X	X	X	X	X
H 1			X	X	X	X	X	X	X	X	X	X	X	X	X	X
H 2		X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
H 3					X	X	X	X	X	X	X	X	X	X	X	X
H 4				X	X	X	X	X	X	X	X	X	X	X	X	X

En la Tabla 7-6 se observa que la técnica SBMLR solo selecciona las características que pertenecen a ZC, SSC y WL, mientras que los canales de MAV no fueron elegidos. En la Tabla 7-7, se seleccionaron todos los canales de ZC, SSC y WL y solo unos pocos de MAV. Esto implica que las características de MAV representan menos información que las otras tres analizadas.

Tabla 7-8. Exactitud obtenida para cada sujeto.

Sujeto	Exactitud de la clasificación		
	Todos	SBMLR	Relief
Mujer 1	85.71 %	87.14 %	85.71 %
Mujer 2	75.71 %	71.43 %	75.71 %
Mujer 3	91.43 %	90.00 %	91.43 %
Mujer 4	92.86 %	91.43 %	92.86 %
Hombre 1	94.29 %	92.86 %	94.29 %
Hombre 2	90.00 %	85.71 %	90.00 %
Hombre 3	91.43 %	91.43 %	91.43 %
Hombre 4	74.29 %	70.00 %	74.29 %
Promedio	86.96 %	85.00 %	86.96 %

Finalmente, en la Tabla 7-8, se muestran los porcentajes de la exactitud obtenida. Esto demuestra que el promedio es muy similar si las características de MAV se eliminan de la matriz de la característica para el caso SBMLR. Y si solo se eliminan algunos de ellos (con Relief), se puede observar el mismo porcentaje.

Para SBMLR, se eliminaron cuatro vectores, incluso siete, y la exactitud obtenida disminuyó menos del 2%. Por otro lado, con la técnica de Relief, los resultados eliminando algunos vectores fueron los mismos que sin eliminar ningún vector; esto implica que no todos los vectores tienen información importante del movimiento.

El proceso de prueba se repitió utilizando todas las características para ZC, WL y SSC, y la exactitud obtenida se muestra en la Tabla 7-9. Los resultados son los mismos que considerando las cuatro características.

Tabla 7-9. Exactitud obtenida para cada sujeto utilizando ZC, WL y SSC.

Sujeto	Exactitud obtenida
Mujer 1	85.71 %
Mujer 2	75.71 %
Mujer 3	91.43 %
Mujer 4	92.86 %
Hombre 1	94.29 %
Hombre 2	90.00 %
Hombre 3	91.43 %
Hombre 4	74.29 %
Promedio	86.96 %

Los resultados de la Tabla 7-9 utilizan las primeras 10 repeticiones del movimiento para entrenamiento del algoritmo y las siguientes 10 para pruebas del mismo, en otras palabras, repetición 1 a la 10 para entrenamiento y repetición 11 a 20 para pruebas.

7.3 Selección del kernel

Como ya se mencionó, la librería cuenta con la facilidad de variar el tipo de kernel a utilizar. Para esta prueba se utilizó un vector aleatorio para la selección de los vectores de entrenamiento; dejando los restantes para prueba. Los vectores quedan de la siguiente manera:

- Prueba: [2,4,8,10,11,13,14,16,18,19]
- Entrenamiento: [1,3,5,6,7,9,12,15,17,20].

La Tabla 7-10 muestra los resultados obtenidos al variar el kernel; el promedio de la exactitud obtenida con el kernel lineal es superior a los otros tres; por lo que es el kernel propuesto para el algoritmo de este trabajo.

Tabla 7-10. Exactitud obtenida con diferentes kernel.

Sujeto	Kernel			
	Lineal	Polinomial	RBF	Sigmoide
Hombre 1	98.57 %	97.14 %	98.57 %	72.86 %
Hombre 2	94.29 %	92.85 %	94.29 %	81.43 %
Hombre 3	94.29 %	91.43 %	94.29 %	90.00 %
Hombre 4	84.29 %	78.57 %	80.00 %	80.00 %
Mujer 1	88.57 %	64.29 %	91.43 %	88.57 %
Mujer 2	88.57 %	74.29 %	87.14 %	64.29 %
Mujer 3	85.71 %	77.14 %	81.43 %	62.86 %
Mujer 4	90.00 %	80.00 %	82.86 %	75.71 %
Promedio	90.54 %	81.96 %	88.75 %	76.96 %

7.4 Validación del algoritmo

Para la validación se utilizó el algoritmo diseñado con la misma base de datos, disponible en línea, utilizada por Sapsanis *et al.*, (2013), con las siguientes características:

- Los experimentos consistieron en sujetar libre y repetidamente diferentes objetos para generar movimientos esenciales de la mano.
- La velocidad y fuerza se dejaron a la voluntad del sujeto.

- Se utilizaron dos electrodos superficiales colocados en el antebrazo, en los músculos Flexor Carpi Ulnaris y Extensor Carpi Radialis, Longus y Brevis [7], el electrodo de referencia en el centro; todos mantenidos en su lugar por bandas elásticas.
- Los datos se recopilaron de 5 sujetos sanos, 3 mujeres y dos hombres, con edad aproximada de 20 a 22 años.
- Se realizaron seis diferentes movimientos, a los cuales se les asignó un nombre de una sola palabra, según corresponda al objeto sostenido (Figura 7.1).

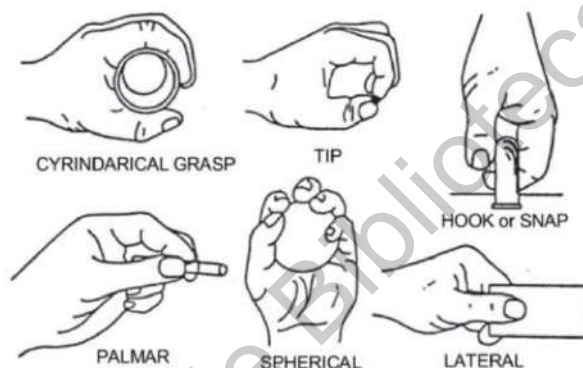


Figura 7.1. Descripción gráfica de los movimientos considerados.

- Cada movimiento fue realizado durante seis segundos.
- Se hicieron un total de 30 repeticiones de cada movimiento.
- Se grabaron dos canales de EMG.
- La frecuencia de muestro de 500 Hz.

De la misma forma que Sapsanis *et al.*, las señales obtenidas de la base de datos pasaron a través de dos filtros, Notch para eliminar la frecuencia de 50 Hz, y un filtro Butterworth pasa altas, eliminando las frecuencias menores a 15 Hz.

La Tabla 7-11 muestra una comparación entre los resultados obtenidos por Sapsanis *et al.*, y los del algoritmo propuesto en este trabajo. En esta se puede observar que el algoritmo mostró mejores resultados en la clasificación de las señales para todos los sujetos de prueba.

Tabla 7-11. Comparativa en exactitud con el trabajo de Sapsanis *et al.*

Sujeto	Exactitud	
	Sapsanis <i>et al.</i>	Autora
Mujer 1	87.25 %	90.00 %
Mujer 2	88.05 %	95.00 %
Mujer 3	85.53 %	90.83 %
Hombre 1	90.42 %	90.83 %
Hombre 2	94.8 %	97.50 %

En la segunda etapa de validación, se hicieron diferentes experimentos, modificando el orden de las repeticiones como entrada del algoritmo de entrenamiento y la prueba del mismo. A continuación, se muestran una serie de tablas con el número de repetición utilizada en entrenamiento y en pruebas para cada experimento, por cada uno de los sujetos de prueba. El número de repetición utilizada se obtuvo de forma aleatoria con el comando *randi* y la semilla “shuffle”.

Tabla 7-12. Repeticiones utilizadas por experimento para Mujer 1.

Exp.	Entrenamiento	Prueba
1	1, 3, 5, 6, 7, 13, 16, 17, 19, 20	2, 4, 8, 9, 10, 11, 12, 14, 15, 18
2	1, 2, 5, 7, 9, 12, 13, 15, 18, 19	3, 4, 6, 8, 10, 11, 14, 16, 17, 20
3	1, 5, 9, 10, 11, 12, 13, 14, 15, 18	2, 3, 4, 6, 7, 8, 16, 17, 19, 20
4	1, 2, 3, 6, 8, 11, 13, 14, 15, 19	4, 5, 7, 9, 10, 12, 16, 17, 18, 20
5	1, 3, 4, 6, 7, 10, 12, 16, 19, 20	2, 5, 8, 9, 11, 13, 14, 15, 17, 18
6	2, 3, 5, 6, 7, 11, 12, 15, 16, 19	1, 4, 8, 9, 10, 13, 14, 17, 18, 20
7	1, 2, 4, 6, 13, 16, 17, 18, 19, 20	3, 5, 7, 8, 9, 10, 11, 12, 14, 15
8	1, 2, 3, 4, 6, 7, 11, 12, 14, 19	5, 8, 9, 10, 13, 15, 16, 17, 18, 20
9	1, 7, 12, 13, 14, 15, 16, 17, 18, 19	2, 3, 4, 5, 6, 8, 9, 10, 11, 20
10	1, 6, 11, 13, 14, 16, 17, 18, 19, 20	1, 6, 11, 13, 14, 16, 17, 18, 19, 20

Tabla 7-13. Repeticiones utilizadas por experimento para Mujer 2.

Exp.	Entrenamiento	Prueba
1	2, 7, 9, 11, 12, 14, 15, 17, 18, 19	1, 3, 4, 5, 6, 8, 10, 13, 16, 20
2	1, 2, 3, 6, 11, 12, 13, 16, 19, 20	4, 5, 7, 8, 9, 10, 14, 15, 17, 18
3	1, 3, 4, 6, 9, 10, 13, 15, 16, 17	2, 5, 7, 8, 11, 12, 14, 18, 19, 20
4	1, 2, 3, 6, 8, 14, 16, 17, 18, 19	4, 5, 7, 9, 10, 11, 12, 13, 15, 20
5	1, 3, 5, 7, 9, 11, 15, 18, 19, 20	2, 4, 6, 8, 10, 12, 13, 14, 16, 17
6	1, 2, 4, 12, 13, 14, 16, 17, 18, 20	3, 5, 6, 7, 8, 9, 10, 11, 15, 19
7	7, 8, 9, 10, 11, 12, 13, 18, 19, 20	1, 2, 3, 4, 5, 6, 14, 15, 16, 17
8	1, 4, 5, 6, 9, 14, 15, 17, 19, 20	2, 3, 7, 8, 10, 11, 12, 13, 16, 18
9	1, 5, 7, 8, 9, 10, 11, 14, 16, 20	2, 3, 4, 6, 12, 13, 15, 17, 18, 19
10	1, 3, 6, 8, 12, 13, 14, 15, 16, 17	2, 4, 5, 7, 9, 10, 11, 18, 19, 20

Tabla 7-14. Repeticiones utilizadas por experimento para Mujer 3.

Exp.	Entrenamiento	Prueba
1	1, 2, 5, 6, 9, 11, 16, 18, 19, 20	3, 4, 7, 8, 10, 12, 13, 14, 15, 17
2	2, 4, 5, 6, 7, 11, 12, 16, 18, 19	1, 3, 8, 9, 10, 13, 14, 15, 17, 20
3	1, 3, 5, 6, 7, 8, 13, 14, 18, 19	2, 4, 9, 10, 11, 12, 15, 16, 17, 20
4	1, 4, 8, 9, 10, 11, 12, 13, 17, 19	2, 3, 5, 6, 7, 14, 15, 16, 18, 20
5	2, 6, 7, 8, 9, 11, 12, 13, 14, 15	1, 3, 4, 5, 10, 16, 17, 18, 19, 20
6	1, 2, 3, 8, 10, 12, 13, 17, 19, 20	4, 5, 6, 7, 9, 11, 14, 15, 16, 18
7	2, 3, 4, 5, 11, 14, 16, 17, 18, 20	1, 6, 7, 8, 9, 10, 12, 13, 15, 19
8	2, 3, 6, 7, 9, 11, 12, 18, 19, 20	1, 4, 5, 8, 10, 13, 14, 15, 16, 17
9	1, 2, 6, 7, 9, 11, 13, 14, 15, 18	3, 4, 5, 8, 10, 12, 16, 17, 19, 20
10	1, 4, 6, 8, 12, 13, 14, 17, 18, 20	2, 3, 5, 7, 9, 10, 11, 15, 16, 19

Tabla 7-15. Repeticiones utilizadas por experimento para Mujer 4.

Exp.	Entrenamiento	Prueba
1	1, 3, 10, 12, 13, 14, 16, 18, 19, 20	2, 4, 5, 6, 7, 8, 9, 11, 15, 17
2	3, 4, 8, 11, 13, 14, 16, 17, 18, 20	1, 2, 5, 6, 7, 9, 10, 12, 15, 19
3	2, 3, 6, 8, 9, 10, 13, 15, 19, 20	1, 4, 5, 7, 11, 12, 14, 16, 17, 18
4	4, 7, 8, 9, 10, 12, 13, 15, 16, 19	1, 2, 3, 5, 6, 11, 14, 17, 18, 20
5	1, 2, 6, 8, 11, 14, 15, 16, 18, 20	3, 4, 5, 7, 9, 10, 12, 13, 17, 19
6	3, 4, 6, 8, 9, 10, 13, 15, 16, 19	1, 2, 5, 7, 11, 12, 14, 17, 18, 20
7	1, 2, 4, 9, 11, 12, 17, 18, 19, 20	3, 5, 6, 7, 8, 10, 13, 14, 15, 16
8	5, 6, 7, 8, 13, 14, 16, 18, 19, 20	1, 2, 3, 4, 5, 9, 10, 11, 12, 15, 17
9	1, 4, 7, 9, 13, 16, 17, 18, 19, 20	2, 3, 5, 6, 8, 10, 11, 12, 14, 15
10	2, 3, 6, 8, 9, 10, 12, 14, 17, 18	1, 4, 5, 7, 11, 13, 15, 16, 19, 20

Tabla 7-16. Repeticiones utilizadas por experimento para Hombre 1.

Exp.	Entrenamiento	Prueba
1	2, 4, 5, 7, 8, 10, 12, 15, 17, 19	1, 3, 6, 9, 11, 13, 14, 16, 18, 20
2	1, 2, 3, 6, 9, 11, 15, 16, 18, 19	4, 5, 7, 8, 10, 12, 13, 14, 17, 20
3	5, 6, 7, 10, 13, 14, 16, 17, 18, 19	1, 2, 3, 4, 8, 9, 11, 12, 15, 20
4	2, 3, 4, 5, 6, 12, 13, 15, 19, 20	1, 7, 8, 9, 10, 11, 14, 16, 17, 18
5	2, 6, 7, 12, 13, 15, 16, 17, 18, 20	1, 3, 4, 5, 8, 9, 10, 11, 14, 19
6	2, 4, 7, 8, 10, 11, 14, 17, 19, 20	1, 3, 5, 6, 9, 12, 13, 15, 16, 18
7	1, 2, 3, 5, 7, 8, 9, 12, 18, 20	4, 6, 10, 11, 13, 14, 15, 16, 17, 19
8	5, 6, 7, 9, 10, 14, 16, 17, 18, 19	1, 2, 3, 4, 8, 11, 12, 13, 15, 20
9	3, 4, 6, 13, 14, 15, 16, 17, 18, 20	1, 2, 5, 7, 8, 9, 10, 11, 12, 19
10	1, 4, 7, 8, 9, 13, 14, 16, 18, 20	2, 3, 5, 6, 10, 11, 12, 15, 17, 19

Tabla 7-17. Repeticiones utilizadas por experimento para Hombre 2.

Exp.	Entrenamiento	Prueba
1	2, 6, 8, 11, 12, 13, 16, 18, 19, 20	1, 3, 4, 5, 7, 9, 10, 14, 15, 17
2	3, 5, 8, 9, 10, 11, 13, 14, 17, 19	1, 2, 4, 6, 7, 12, 15, 16, 18, 20
3	1, 2, 4, 8, 9, 10, 11, 13, 17, 20	3, 5, 6, 7, 12, 14, 15, 16, 18, 19
4	2, 3, 4, 7, 8, 11, 12, 15, 18, 19	1, 5, 6, 9, 10, 13, 14, 16, 17, 20
5	1, 5, 7, 8, 9, 10, 13, 15, 17, 19	2, 3, 4, 6, 11, 12, 14, 16, 18, 20
6	1, 3, 11, 12, 16, 17, 18, 19, 20	2, 4, 5, 6, 7, 8, 9, 10, 14, 15
7	2, 4, 6, 7, 13, 14, 15, 18, 19, 20	1, 3, 5, 8, 9, 10, 11, 12, 16, 17
8	1, 2, 3, 4, 7, 9, 13, 17, 18, 19	5, 6, 8, 10, 11, 12, 14, 15, 16, 20
9	1, 2, 3, 5, 6, 7, 8, 13, 16, 20	4, 9, 10, 11, 12, 14, 15, 17, 18, 19
10	1, 2, 3, 5, 6, 8, 11, 17, 18, 19	4, 7, 9, 10, 12, 13, 14, 15, 16, 20

Tabla 7-18. Repeticiones utilizadas por experimento para Hombre 3.

Exp.	Entrenamiento	Prueba
1	2, 4, 6, 7, 9, 11, 12, 16, 17, 18	1, 3, 5, 8, 10, 11, 14, 15, 19, 20
2	2, 4, 8, 10, 11, 14, 15, 16, 17, 19	1, 3, 5, 6, 7, 9, 12, 13, 18, 20
3	3, 4, 5, 6, 8, 10, 11, 12, 17, 20	1, 2, 7, 9, 13, 14, 15, 16, 18, 19
4	1, 3, 4, 6, 8, 9, 14, 15, 17, 18	2, 5, 7, 10, 11, 12, 13, 16, 19, 20
5	1, 2, 3, 6, 11, 13, 14, 17, 19, 20	4, 5, 7, 8, 9, 10, 12, 15, 16, 18
6	1, 3, 4, 7, 8, 10, 14, 15, 17, 19	2, 5, 6, 9, 11, 12, 13, 16, 18, 20
7	2, 3, 4, 8, 9, 11, 12, 13, 16, 17	1, 5, 6, 7, 10, 14, 15, 18, 19, 20
8	1, 3, 6, 9, 10, 11, 12, 16, 17, 19	2, 4, 5, 7, 8, 13, 14, 15, 18, 20
9	2, 5, 6, 7, 10, 12, 15, 16, 17, 19	1, 3, 4, 8, 9, 11, 13, 14, 18, 20
10	1, 2, 5, 6, 7, 9, 11, 13, 14, 20	3, 4, 8, 10, 12, 15, 16, 17, 18, 19

Tabla 7-19. Repeticiones utilizadas por experimento para Hombre 4.

Exp.	Entrenamiento	Prueba
1	1, 2, 5, 6, 7, 8, 11, 13, 16, 19	3, 4, 9, 10, 12, 14, 15, 17, 18, 20
2	2, 3, 4, 8, 9, 12, 13, 16, 17, 19	1, 5, 6, 7, 10, 11, 14, 15, 18, 20
3	2, 3, 5, 6, 9, 10, 12, 14, 17, 19	1, 4, 7, 8, 11, 13, 15, 16, 18, 20
4	1, 4, 9, 11, 12, 13, 14, 15, 19, 20	2, 3, 5, 6, 7, 8, 10, 16, 17, 18
5	1, 3, 5, 8, 10, 13, 14, 15, 19, 20	2, 4, 6, 7, 9, 11, 12, 16, 17, 18
6	1, 2, 5, 6, 7, 9, 10, 11, 16, 20	3, 4, 8, 12, 13, 14, 15, 17, 18, 19
7	1, 3, 4, 9, 10, 12, 13, 16, 17, 19	2, 5, 6, 7, 8, 11, 14, 15, 18, 20
8	2, 3, 4, 6, 8, 11, 12, 13, 16, 19	1, 5, 7, 9, 10, 14, 15, 17, 18, 20
9	2, 4, 6, 8, 10, 12, 13, 16, 17, 19	1, 3, 5, 7, 9, 11, 14, 15, 18, 20
10	1, 7, 9, 10, 11, 12, 17, 18, 19, 20	2, 3, 4, 5, 6, 8, 13, 14, 15, 16

Para un mejor análisis de los datos obtenidos, se realizaron matrices de confusión en cada una de las pruebas finales; anexando el cálculo de la especificidad, sensibilidad, exactitud y precisión en las filas de la parte inferior de la matriz, para cada uno de los 7 movimientos ejecutados.

En otras palabras, de cada prueba hecha de cada sujeto se realizó una matriz de confusión, obteniendo un total de 70 matrices. La Tabla 7-20 tiene la matriz de confusión promedio de la prueba 1 de los 8 sujetos de prueba; de la misma forma, de la Tabla 7-21 a la Tabla 7-29 para las siguientes 9 pruebas.

Tabla 7-20. Matriz de confusión de la prueba 1.

	C1	C2	C3	C4	C5	C6	C7
C1	10	0	0	0	0	0	0
C2	0.3	8.9	0.3	0.4	0	0.1	0.1
C3	0	0.1	8.6	0.5	0.4	0.1	0.3
C4	0.1	0.6	0.1	8.5	0.3	0.3	0.1
C5	0.3	0	0.3	0.5	8.8	0.3	0
C6	0	0.5	0	0	0	9.3	0.3
C7	0	0	0.1	0	0	0	9.9
SPE	0.99	0.98	0.99	0.98	0.99	0.99	0.99
SEN	1.00	0.89	0.86	0.85	0.88	0.93	0.99
ACC	0.99	0.97	0.97	0.96	0.97	0.98	0.99
PPR	0.94	0.88	0.92	0.86	0.93	0.93	0.93

Los resultados en la sensibilidad de la Tabla 7-20 indican que el algoritmo no fue tan efectivo al diferenciar entre los movimientos 3 y 4; y la precisión confirma que el 4° movimiento fue el peor clasificado; al tener un mayor número de falsos positivos.

Tabla 7-21. Matriz de confusión de la prueba 2.

	C1	C2	C3	C4	C5	C6	C7
C1	9.9	0	0	0	0.1	0	0
C2	0	8.9	0.5	0.3	0	0.1	0.3
C3	0	0.3	8.3	0.9	0.4	0	0.3
C4	0.1	0.4	0.9	8	0.4	0	0.3
C5	0.6	0	0.3	0.4	8.6	0.1	0
C6	0	0.5	0.3	0	0	9.3	0
C7	0	0	0	0	0	0	10
SPE	0.99	0.98	0.97	0.98	0.99	1.00	0.99
SEN	0.99	0.89	0.83	0.80	0.86	0.93	1.00
ACC	0.99	0.97	0.95	0.95	0.97	0.99	0.99
PPR	0.93	0.89	0.81	0.84	0.91	0.97	0.93

Los resultados en la sensibilidad de la Tabla 7-21 indican que los movimientos 3 y 4 fueron confundidos más veces comparados con los otros movimientos, lo que es comprobado con la precisión, al obtener en estos movimientos el promedio más bajo.

Tabla 7-22. Matriz de confusión de la prueba 3.

	C1	C2	C3	C4	C5	C6	C7
C1	9.8	0	0	0.1	0.1	0	0
C2	0	9	0	0.5	0	0.5	0
C3	0	0.8	7.6	1	0	0.3	0.4
C4	0.1	0.3	0.3	8.9	0.3	0	0.3
C5	0.1	0.1	0.3	0.1	9.4	0	0
C6	0	0.5	0.1	0	0.4	9	0
C7	0	0.1	0	0	0	0	9.9
SPE	1.00	0.97	0.99	0.97	0.99	0.99	0.99
SEN	0.98	0.90	0.76	0.89	0.94	0.90	0.99
ACC	0.99	0.96	0.96	0.96	0.98	0.98	0.99
PPR	0.98	0.84	0.92	0.84	0.93	0.92	0.94

En la Tabla 7-22, los movimientos 3 y 4 tienen los promedios bajos, el movimiento 3 fue el que más errores tuvo al clasificarse, ya que fue confundido con otros movimientos. Por otra parte, la precisión más baja fue obtenida en los movimientos 2 y 4, ya que otras repeticiones de otros movimientos fueron confundidos con estos dos.

Tabla 7-23. Matriz de confusión de la prueba 4.

	C1	C2	C3	C4	C5	C6	C7
C1	9.6	0	0	0	0.4	0	0
C2	0	9.1	0.4	0.4	0	0.1	0
C3	0	0.8	8.4	0.5	0.1	0	0.3
C4	0	0.9	0.6	7.4	0.6	0	0.5
C5	0.3	0	0.3	0.6	8.6	0.3	0
C6	0	0.5	0.3	0	0.1	9.1	0
C7	0	0	0.1	0	0	0	9.9
SPE	1.00	0.96	0.97	0.98	0.98	0.99	0.99
SEN	0.96	0.91	0.84	0.74	0.86	0.91	0.99
ACC	0.99	0.96	0.95	0.94	0.96	0.98	0.99
PPR	0.97	0.81	0.84	0.83	0.87	0.96	0.93

En la Tabla 7-23 el 4° movimiento tiene una sensibilidad de 0.74, 0.1 más baja que la siguiente con la calificación más baja; es el movimiento con más repeticiones confundidas con el resto de los movimientos. Por otra parte, el movimiento con la precisión más baja, fue el 2°, ya que repeticiones de otros movimientos fueron confundidos con éste, principalmente el movimiento 3 y 4.

Tabla 7-24. Matriz de confusión de la prueba 5.

	C1	C2	C3	C4	C5	C6	C7
C1	10	0	0	0	0	0	0
C2	0.3	7.8	0.8	0.4	0.1	0.8	0
C3	0.1	0.4	9	0.1	0.1	0	0.3
C4	0.1	0.4	0.9	7.9	0.3	0	0.5
C5	0.3	0.1	0.3	0.4	8.9	0.1	0
C6	0	0.5	0.3	0	0	9.1	0.1
C7	0	0	0	0.1	0	0	9.9
SPE	0.99	0.98	0.96	0.98	0.99	0.99	0.99
SEN	1.00	0.78	0.90	0.79	0.89	0.91	0.99
ACC	0.99	0.95	0.96	0.96	0.98	0.98	0.99
PPR	0.93	0.85	0.81	0.89	0.95	0.91	0.92

En la prueba 5 (Tabla 7-24), la matriz de confusión indica que los movimientos 2, 3 y 4 mal clasificados, principalmente los movimientos 2 y 4, como se ve en la sensibilidad, ya que muestra los resultados más bajos. La precisión del movimiento 3 fue el menos consistente.

Tabla 7-25. Matriz de confusión de la prueba 6.

	C1	C2	C3	C4	C5	C6	C7
C1	9.6	0	0	0	0.4	0	0
C2	0	8.6	0.3	0.5	0	0.5	0.1
C3	0	0	7.9	1	0.4	0.4	0.4
C4	0	0.3	0.3	8.8	0.3	0.1	0.4
C5	0.1	0.1	0.3	0.3	9.1	0.1	0
C6	0	0.6	0.1	0	0.3	9	0
C7	0	0	0.3	0	0	0	9.8
SPE	1.00	0.98	0.98	0.97	0.98	0.98	0.99
SEN	0.96	0.86	0.79	0.88	0.91	0.90	0.98
ACC	0.99	0.97	0.95	0.96	0.97	0.97	0.98
PPR	0.99	0.90	0.88	0.83	0.88	0.89	0.92

En la prueba 6 (Tabla 7-25) las clases 2, 3 y 4 muestran valores de sensibilidad bajos; sin embargo el movimiento 3 fue en el que más errores de clasificación hubo. Además, en la clase 4 la precisión fue la más baja, lo que indica que fue la clase más dispersa.

Tabla 7-26. Matriz de confusión de la prueba 7.

	C1	C2	C3	C4	C5	C6	C7
C1	9.9	0	0	0	0.1	0	0
C2	0	8.9	0.3	0.8	0	0.1	0
C3	0.1	0.3	8.6	0.3	0.5	0.1	0.1
C4	0.1	0.3	0.9	8	0.4	0	0.4
C5	0.6	0	0.1	0.4	8.8	0.1	0
C6	0	0.6	0.3	0	0.4	8.6	0.1
C7	0	0	0.1	0	0	0	9.9
SPE	0.99	0.98	0.97	0.98	0.98	0.99	0.99
SEN	0.99	0.89	0.86	0.80	0.88	0.86	0.99
ACC	0.99	0.97	0.96	0.95	0.96	0.98	0.99
PPR	0.92	0.89	0.84	0.85	0.86	0.96	0.94

En la Tabla 7-26 que tiene la prueba 7, la clase 4 mostró el valor más bajo y las clases 3 y 6 el valor más bajo siguiente; sin embargo, la precisión confirma que la clase 3 fue la más dispersa.

Tabla 7-27. Matriz de confusión de la prueba 8.

	C1	C2	C3	C4	C5	C6	C7
C1	9.9	0	0	0	0.1	0	0
C2	0	8.8	0.5	0.4	0	0.3	0.1
C3	0	0.6	8.4	0.8	0	0.3	0
C4	0.1	0.4	0.4	8	0.8	0	0.4
C5	0.5	0	0.1	0.4	8.8	0.3	0
C6	0	0.3	0.3	0	0	9.3	0.3
C7	0	0	0.1	0	0	0	9.9
SPE	0.99	0.98	0.98	0.98	0.99	0.99	0.99
SEN	0.99	0.88	0.84	0.80	0.88	0.93	0.99
ACC	0.99	0.96	0.96	0.95	0.97	0.98	0.99
PPR	0.94	0.88	0.86	0.84	0.91	0.93	0.93

A pesar de que los valores de sensibilidad y precisión de la prueba 8 (Tabla 7-27) no son tan bajos como algunas otras pruebas, la clase 4 tiene el valor más pequeño comparado con las otras clases y la precisión también indica que es el movimiento más disperso en esta prueba.

Tabla 7-28. Matriz de confusión de la prueba 9.

	C1	C2	C3	C4	C5	C6	C7
C1	9.9	0	0	0	0.1	0	0
C2	0	8.5	0.9	0.5	0	0.1	0
C3	0.1	0	9.3	0.4	0.1	0.1	0
C4	0.3	0.3	0.3	8.1	0.3	0.4	0.5
C5	0.3	0	0.3	0.5	8.8	0.3	0
C6	0	0.6	0	0	0	9.4	0
C7	0	0	0.3	0	0	0	9.8
SPE	0.99	0.99	0.97	0.98	0.99	0.99	0.99
SEN	0.99	0.85	0.93	0.81	0.88	0.94	0.98
ACC	0.99	0.97	0.97	0.95	0.98	0.98	0.99
PPR	0.94	0.91	0.85	0.86	0.95	0.91	0.95

La prueba 9 (Tabla 7-28) se comporta de forma similar que la prueba 8, con el movimiento 4 con la sensibilidad más pequeña; sin embargo, la clase más dispersa es indicada por la precisión, y corresponde a la clase 3.

Tabla 7-29. Matriz de confusión de la prueba 10.

	C1	C2	C3	C4	C5	C6	C7
C1	9.9	0	0	0	0.1	0	0
C2	0	8.3	0.1	0.9	0	0.8	0
C3	0.1	0.4	8.9	0.1	0.1	0.3	0.1
C4	0.3	0.5	0.8	7.3	0.6	0	0.6
C5	0.4	0	0.4	0.8	8.4	0.1	0
C6	0	0.4	0.1	0	0.1	9.3	0.1
C7	0	0.1	0.1	0	0	0	9.8
SPE	0.99	0.98	0.98	0.97	0.98	0.98	0.99
SEN	0.99	0.83	0.89	0.73	0.84	0.93	0.98
ACC	0.99	0.96	0.96	0.94	0.96	0.97	0.98
PPR	0.93	0.86	0.86	0.81	0.89	0.89	0.92

Durante la prueba 10, la clase 4 mostró el valor de sensibilidad más pequeño; además la precisión indica que también esa clase es la más dispersa.

Tabla 7-30. Matriz de confusión promedio.

	C1	C2	C3	C4	C5	C6	C7
C1	9.8	0	0	0	0.2	0	0
C2	0.1	8.7	0.4	0.5	0	0.3	0.1
C3	0.1	0.4	8.5	0.6	0.2	0.2	0.2
C4	0.1	0.4	0.5	8.1	0.4	0.1	0.4
C5	0.3	0	0.2	0.4	8.8	0.2	0
C6	0	0.5	0.2	0	0.1	9.1	0.1
C7	0	0	0.1	0	0	0	9.9
SPE	0.99	0.98	0.98	0.98	0.99	0.99	0.99
SEN	0.98	0.87	0.85	0.81	0.88	0.91	0.99
ACC	0.99	0.96	0.96	0.95	0.97	0.98	0.99
PPR	0.95	0.87	0.86	0.84	0.91	0.93	0.93

La matriz de confusión de la Tabla 7-30 muestra que, en general, el reposo (C7) es el movimiento más fácil de identificar; con menos errores, seguido de la clase 1, con resultado similar. El movimiento 4 tiene casi 20% menos que el movimiento 1, lo que indica que es el que tuvo más problemas para identificarse, como lo indica la sensibilidad. Además, en la precisión, las clases 2, 3 y 4 tienen los valores más pequeños, lo que indica que son los movimientos más dispersos, lo que indica que tal vez se parezcan entre ellos, que los movimientos musculares sean parecidos.

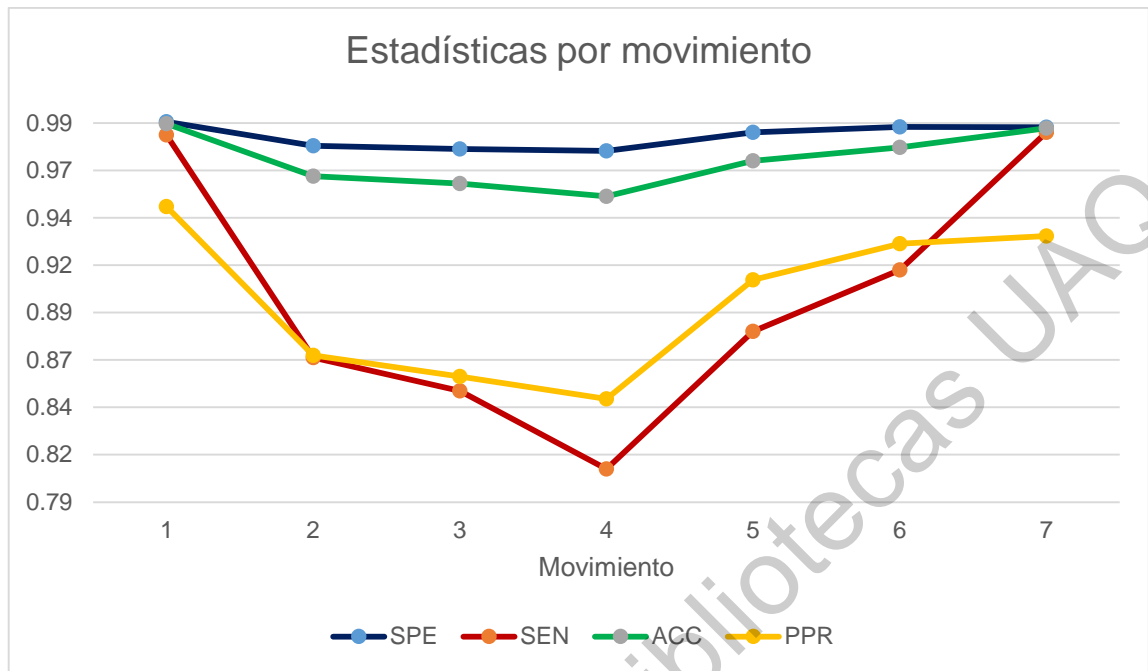


Figura 7.2. Gráfica con estadísticas de sensibilidad, especificidad, exactitud y precisión promedio, obtenidas por cada movimiento.

La gráfica de la Figura 7.2 muestra que la clase 4 fue la que más problemas causó en la clasificación. La sensibilidad tiene un valor significativamente más pequeño en la clase 4, comparada con las clases 1 y 7; de la misma forma que la precisión, lo que indica la dispersión en este movimiento. La especificidad y exactitud tienen los valores más consistentes y más altos en todas clases, lo que indica que el algoritmo es capaz de clasificar correctamente y además lo hace más del 95% de los casos.




Figura 7.3. Especificidad por movimiento.




Figura 7.4. Sensibilidad con líneas de tolerancia por movimiento.

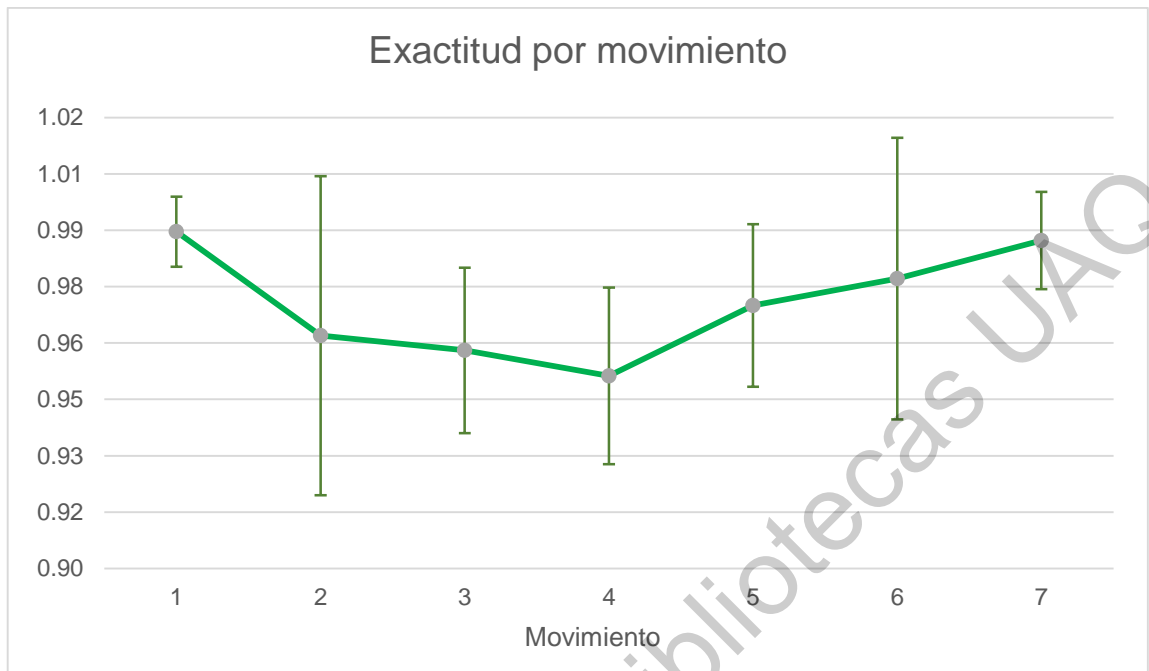


Figura 7.5. Exactitud con líneas de tolerancia por movimiento.




Figura 7.6. Precisión con líneas de tolerancia por movimiento.

En las Figura 7.3, Figura 7.4, Figura 7.5, Figura 7.6 se muestran los promedios de la Figura 7.2 de forma individual (especificidad, sensibilidad, exactitud y precisión) y sus líneas de tolerancia con el error obtenido en cada movimiento.



Figura 7.7. Gráfica de especificidad por prueba.

La gráfica de la Figura 7.7 muestra resultados de especificidad de la clasificación superiores a 0.98, es otras palabras, más del 98% en cada una de las pruebas; lo que indica que, variar los vectores de entrenamiento y prueba no hacen una diferencia significativa en la capacidad del algoritmo de diferenciar entre cada clase.



Figura 7.8. Gráfica de sensibilidad por prueba.

La sensibilidad de 0.88 a 0.91, como se ve en la gráfica de la Figura 7.8; variar los vectores de entrenamiento y prueba no presentan una gran diferencia. Por otra parte, indican que el algoritmo realiza más del 88% de las clasificaciones de forma acertada.




Figura 7.9. Gráfica de exactitud por prueba.

La exactitud por prueba mostrada en la gráfica de la Figura 7.9, el valor más pequeño de 0.966, indica que el promedio de clasificación del algoritmo es 96.6%; en otras palabras, muy pocas veces realiza una clasificación errónea.

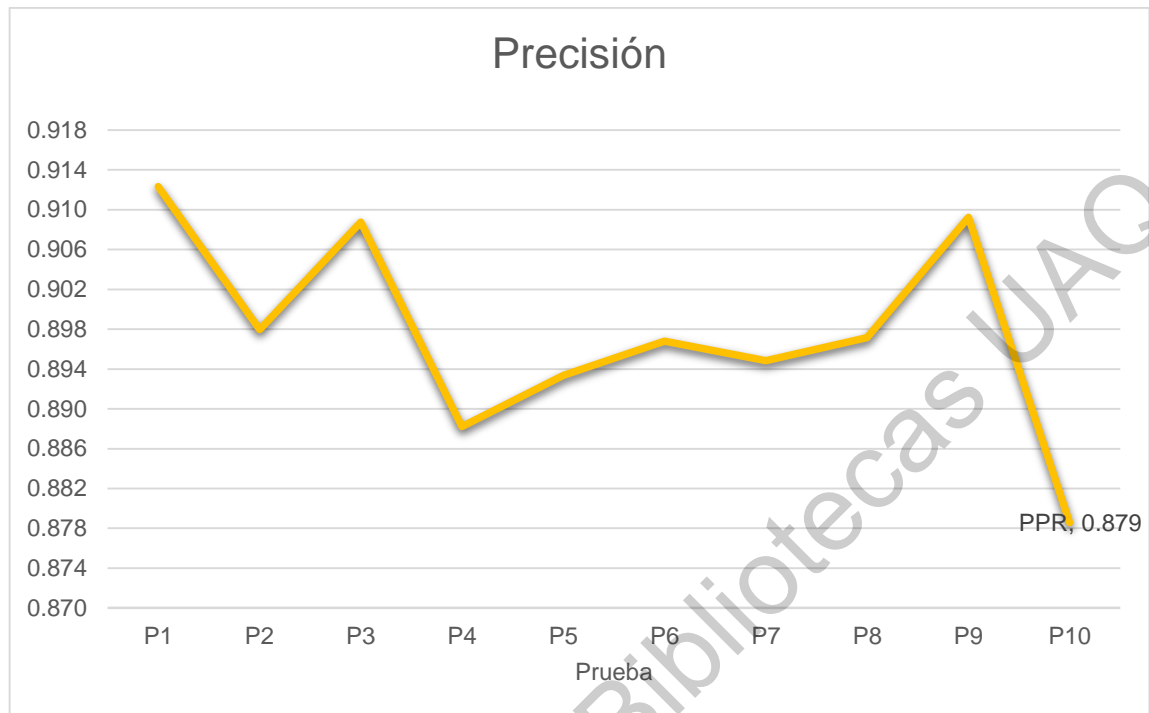


Figura 7.10. Gráfica de precisión por prueba.

Finalmente, en la gráfica de la Figura 7.10 se muestra el comportamiento de la precisión de la clasificación, el valor mínimo es de 0.879. Esto indica que el algoritmo presenta un desempeño superior al 87.9% al clasificar de la misma forma. Las pruebas mostraron que el desempeño del algoritmo es bueno a pesar de que los movimientos son similares.

En resumen, el algoritmo diseñado para la clasificación de señales EMG con base en SVMs; propuesto en la Figura 6.13, utiliza los algoritmos específicos listados en la Figura 7.11.

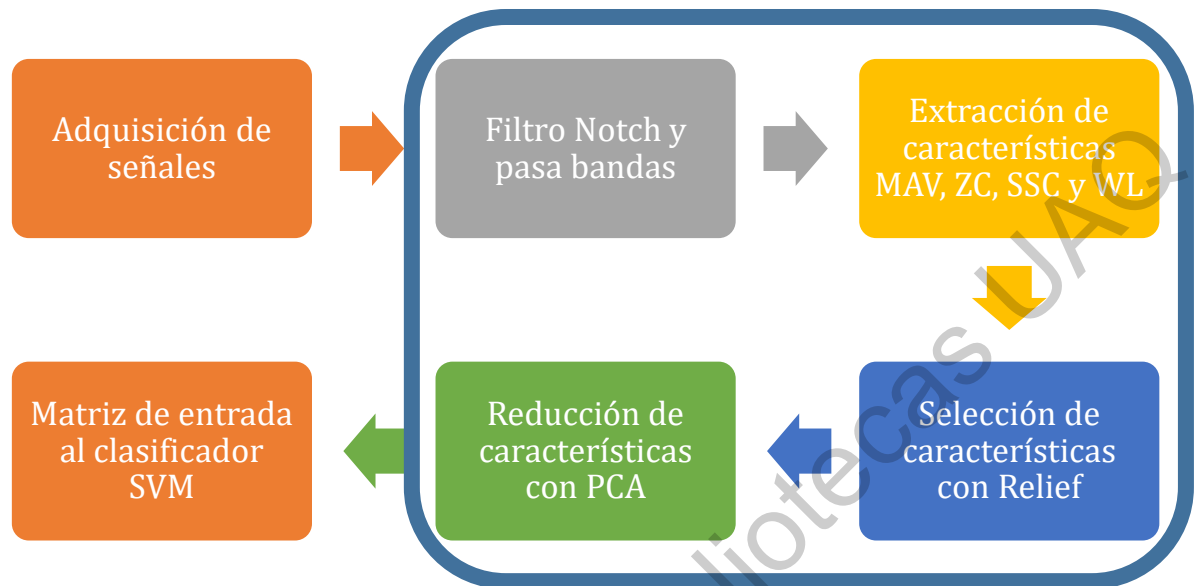


Figura 7.11. Algoritmo propuesto para la clasificación de señales de EMG.

8 Conclusiones

Este proyecto de tesis tuvo como propósito encontrar un algoritmo que utilice SVMs que aumente la precisión de la clasificación, para poder utilizarse en el control de prótesis. Los métodos de selección de características ayudaron a determinar cuáles de ellas son importantes a considerar para describir mejor el movimiento. Con base en estos resultados obtenidos, se propusieron las características y después de considerar algunos métodos de reducción de dimensionalidad, se definió que los PCAs eran los adecuados para el algoritmo propuesto.

Utilizando el algoritmo propuesto se obtienen resultados de las clasificaciones del 100 % en la mayoría de los casos, por lo que se deduce que funciona y que además se cumplió con el objetivo de estudio; ya que, comparado con otros algoritmos mencionados en la literatura, exhibe en promedio mejores resultados. Además, se pudo observar que, para obtener mejores resultados en la exactitud de la clasificación, no es necesario sólo agregar

características de las señales al azar; conviene también revisar si la característica añadida describe la señal de la mejor forma de acuerdo al uso que se le dará a la misma; para lo que se usaron los algoritmos de selección de características. En un sentido similar, el uso de más canales para el análisis del movimiento no garantiza mejores resultados, es importante que la señal añadida tenga información importante.

Por otra parte, es valioso recalcar que, para extraer las señales de los músculos se diseñó una tarjeta de adquisición de datos inalámbrica; esto es, que se comunica con la computadora utilizando una señal bluetooth, lo que facilita su procesamiento y le permite al usuario portar con el sistema de adquisición sin que se esté “unido” con cables a la computadora. De la misma forma, en un futuro, las personas con amputaciones transtibiales que deseen adquirir una prótesis que utilice el sistema propuesto, podrían tener colocados los electrodos en la pierna sin la necesidad de que éstos estén conectados a la prótesis a través de cables, lo que es más cómodo y fácil de usar.

9 Referencias

Akhmadeev, K., E. Rampone, T. Yu, Y. Aoustin, and E. L. Carpentier. 2017. A testing system for a real-time gesture classification using surface EMG. *IFAC-PapersOnLine*. 50:11498–11503. doi:10.1016/j.ifacol.2017.08.1602.

Al-Assaf, Y., and H. Al-Nashash. 2005. Surface myoelectric signal classification for prostheses control. *J Med Eng Technol*. 29:203–207. doi:10.1080/03091900412331289906.

Alkan, A., and M. Günay. 2012. Identification of EMG signals using discriminant analysis and SVM classifier. *Expert Systems with Applications*. 39:44–47. doi:10.1016/j.eswa.2011.06.043.

Álvarez Illán, I. 2009. Análisis en Componentes de Imágenes Funcionales para la Ayuda al Diagnóstico de la Enfermedad del Alzheimer [Tesis de Doctorado]. Universidad de Granada, Granada, España.

Andrade, A. O., A. A. Pereira, S. Walter, R. Almeida, R. Loureiro, D. Compagna, and P. J. Kyberd. 2014. Bridging the gap between robotic technology and health care. *Biomedical Signal Processing and Control*. 10:65–78. doi:10.1016/j.bspc.2013.12.009.

Arredondo, A., and E. De Icaza. 2011. Costos de la Diabetes en América Latina: Evidencias del Caso Mexicano. *Value in Health*. 14:S85–S88. doi:10.1016/j.jval.2011.05.022.

Asghari Oskoei, M., and H. Hu. 2007. Myoelectric control systems—A survey. *Biomedical Signal Processing and Control*. 2:275–294. doi:10.1016/j.bspc.2007.07.009.

Azar, A. T., H. I. Elshazly, A. E. Hassanien, and A. M. Elkorany. 2014. A random forest classifier for lymph diseases. *Computer Methods and Programs in Biomedicine*. 113:465–473. doi:10.1016/j.cmpb.2013.11.004.

Barone, L. R., C. E. Rodríguez, M. L. Ghiglioni, C. D. González, and S. S. Luna. 2012. *Anatomía y fisiología del cuerpo humano*. 1°. Cultural Librería Americana S. A., Argentina.

Boulton, A. J. M., D. G. Armstrong, S. F. Albert, R. G. Frykberg, R. Hellman, M. S. Kirkman, L. A. Lavery, J. W. LeMaster, J. L. Mills, M. J. Mueller, P. Sheehan, and D. K. Wukich. 2008. Comprehensive Foot Examination and Risk Assessment. *Diabetes Care*. 31:1679–1685. doi:10.2337/dc08-9021.

Camargo, J., and A. Young. 2019. Feature Selection and Non-Linear Classifiers: Effects on Simultaneous Motion Recognition in Upper Limb. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 27:743–750. doi:10.1109/TNSRE.2019.2903986.

Cawley, G. C., N. L. Talbot, and M. Girolami. 2007. Sparse Multinomial Logistic Regression via Bayesian L1 Regularisation. In: B. Schölkopf, J. C. Platt, and T. Hoffman, editors. *Advances in Neural Information Processing Systems 19*. MIT Press. p. 209–216. Available from: <http://papers.nips.cc/paper/3155-sparse-multinomial-logistic-regression-via-bayesian-l1-regularisation.pdf>

Chan, A. D. C., and K. B. Englehart. 2005. Continuous myoelectric control for powered prostheses using hidden Markov models. *IEEE Trans Biomed Eng*. 52:121–124. doi:10.1109/TBME.2004.836492.

Chan, F. H. Y., Y.-S. Yang, F. K. Lam, Y.-T. Zhang, and P. A. Parker. 2000. Fuzzy EMG classification for prosthesis control. *IEEE Transactions on Rehabilitation Engineering*. 8:305–311. doi:10.1109/86.867872.

Chatterjee, R., T. Maitra, S. Hafizul Islam, M. M. Hassan, A. Alamri, and G. Fortino. 2019. A novel machine learning based feature selection for motor imagery EEG signal classification in Internet of medical things environment. *Future Generation Computer Systems*. 98:419–434. doi:10.1016/j.future.2019.01.048.

Chen, K., F.-Y. Zhou, and X.-F. Yuan. 2019. Hybrid particle swarm optimization with spiral-shaped mechanism for feature selection. *Expert Systems with Applications*. 128:140–156. doi:10.1016/j.eswa.2019.03.039.

Chmielnicki, W., I. Rotermań-Konieczna, and K. Stapor. 2012. An improved protein fold recognition with support vector machines. *Expert Systems*. 29:200–211. doi:10.1111/j.1468-0394.2010.00572.x.

Cisneros-González, N., I. de J. Ascencio-Montiel, V. N. Libreros-Bango, H. Rodríguez-Vázquez, Á. Campos-Hernández, J. Dávila-Torres, J. Kumate-Rodríguez, and V. H. Borja-Aburto. 2016. Índice de amputaciones de extremidades inferiores en pacientes con diabetes. *Rev Med Inst Mex Seguro Soc*. 54:472–479.

Cover, T. M., and J. A. Thomas. 1991. *Elements of Information Theory*. 1st. John Wiley & Sons, Inc., City College of New York.

Dhindsa, I. S., R. Agarwal, and H. S. Ryait. 2019. Performance evaluation of various classifiers for predicting knee angle from electromyography signals. *Expert Systems*. 36:1–14. doi:10.1111/exsy.12381.

Duda, R. O., P. E. Hart, and D. G. Stork. 2000. *Pattern Classification (2Nd Edition)*. Wiley-Interscience, New York, NY, USA.

Eibe, F., M. A. Hall, and I. H. Witten. 2016. The WEKA Workbench. Online Appendix for “Data Mining: Practical Machine Learning Tools and Techniques.” Morgan Kaufmann. Available from: <https://www.cs.waikato.ac.nz/ml/index.html>

Englehart, K., B. Hudgin, and P. A. Parker. 2001. A wavelet-based continuous classification scheme for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*. 48:302–311. doi:10.1109/10.914793.

Englehart, K., B. Hudgins, and A. Chan. 2003. Continuous multifunction myoelectric control using pattern recognition.

Englehart, K., B. Hudgins, P. A. Parker, and M. Stevenson. 1999. Classification of the myoelectric signal using time-frequency based representations. *Medical Engineering & Physics*. 21:431–438. doi:10.1016/S1350-4533(99)00066-1.

Erik Scheme, K. E. 2010. A One-Versus-One Classifier for Improved Robustness of Myoelectric Control.

Farina, D., and R. Merletti. 2004. Biophysics of the generation of EMG signals. In: *Electromyography: Physiology, Engineering, and Noninvasive Applications*. Vol. 1. 1st ed. John Wiley & Sons. p. 520.

Farrell, T. R., and R. F. Weir. 2008. A Comparison of the Effects of Electrode Implantation and Targeting on Pattern Classification Accuracy for Prosthesis Control. *IEEE Transactions on Biomedical Engineering*. 55:2198–2211. doi:10.1109/TBME.2008.923917.

Fisher, C. K., and P. Mehta. 2014. Fast Bayesian Feature Selection for High Dimensional Linear Regression in Genomics via the Ising Approximation. arXiv:1407.8187 [cs, q-bio, stat]. Available from: <http://arxiv.org/abs/1407.8187>

Fougner, A. L. 2007. Proportional myoelectric control of a multifunction upper-limb prosthesis [Master of Science in Engineering cybernetics]. Norwegian University of Science and Technology, Canadá.

Geethanjali, P. 2016. A mechatronics platform to study prosthetic hand control using EMG signals. *Australas Phys Eng Sci Med.* 39:765–771. doi:10.1007/s13246-016-0458-6.

Guo, X., P. Yang, L.-F. Li, and W.-L. Yan. 2004. Study and analysis of surface EMG for the lower limb prosthesis. In: *Proceedings of 2004 International Conference on Machine Learning and Cybernetics (IEEE Cat. No.04EX826)*. Vol. 6. p. 3736–3740 vol.6.

Guo, Y., X. Yin, X. Zhao, D. Yang, and Y. Bai. 2019. Hyperspectral image classification with SVM and guided filter. *EURASIP Journal on Wireless Communications and Networking.* 2019. doi:10.1186/s13638-019-1346-z.

Hakonen, M., H. Piitulainen, and A. Visala. 2015. Current state of digital signal processing in myoelectric interfaces and related applications. *Biomedical Signal Processing and Control.* 18:334–359. doi:10.1016/j.bspc.2015.02.009.

Hall, M. A. 1999. *Correlation-based Feature Selection for Machine Learning [Computer Science]*. The University of Waikato, Hamilton, New Zeland.

Hassan, H. F., S. J. Abou-Loukh, and I. K. Ibraheem. 2019. Teleoperated robotic arm movement using electromyography signal with wearable Myo armband. *Journal of King Saud University - Engineering Sciences.* doi:10.1016/j.jksues.2019.05.001. Available from: <https://www.sciencedirect.com/science/article/pii/S1018363919300340>

He, W., Y. He, B. Li, and C. Zhang. 2020. A Naive-Bayes-Based Fault Diagnosis Approach for Analog Circuit by Using Image-Oriented Feature Extraction and Selection Technique. *IEEE Access.* 8:5065–5079. doi:10.1109/ACCESS.2018.2888950.

Huang, H.-P., and C.-Y. Chen. 1999. Development of a myoelectric discrimination system for a multi-degree prosthetic hand. In: *Proceedings 1999 IEEE International Conference on Robotics and Automation (Cat. No.99CH36288C)*. Vol. 3. p. 2392–2397 vol.3.

Hudgins, B., P. Parker, and R. N. Scott. 1993. A new strategy for multifunction myoelectric control. *IEEE Trans Biomed Eng.* 40:82–94. doi:10.1109/10.204774.

Ibrahim Aly, H., S. Youssef, and C. Fathy. 2018. Hybrid Brain Computer Interface for Movement Control of Upper Limb Prostheses. In: p. 1–6.

Kalantari, A., A. Kamsin, S. Shamshirband, A. Gani, H. Alinejad-Rokny, and A. T. Chronopoulos. 2018. Computational intelligence approaches for classification of medical data: State-of-the-art, future challenges and research directions. *Neurocomputing*. 276:2–22. doi:10.1016/j.neucom.2017.01.126.

Khan, A., and A. R. Baig. 2015. Multi-Objective Feature Subset Selection using Non-dominated Sorting Genetic Algorithm. *Journal of Applied Research and Technology*. 13:145–159. doi:10.1016/S1665-6423(15)30013-4.

Kohavi, R., and G. H. John. 1997. Wrappers for feature subset selection. *Artificial Intelligence*. 97:273–324. doi:10.1016/S0004-3702(97)00043-X.

Li, X., P. Fang, L. Tian, and G. Li. 2017. Increasing the robustness against force variation in EMG motion classification by common spatial patterns. In: 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). p. 406–409.

Liu, H., and H. Motoda. 2008. *Computational Methods of Feature Selection* (Chapman & Hall/Crc Data Mining and Knowledge Discovery Series). Chapman & Hall/CRC.

Liu, J. 2014. Feature dimensionality reduction for myoelectric pattern recognition: A comparison study of feature selection and feature projection methods. *Medical Engineering & Physics*. 36:1716–1720. doi:10.1016/j.medengphy.2014.09.011.

Liu, J. 2015. Adaptive myoelectric pattern recognition toward improved multifunctional prosthesis control. *Medical Engineering & Physics*. 37:424–430. doi:10.1016/j.medengphy.2015.02.005.

Liu, Y.-H., H.-P. Huang, and C.-H. Weng. 2007. Recognition of Electromyographic Signals Using Cascaded Kernel Learning Machine. *IEEE/ASME Transactions on Mechatronics*. 12:253–264. doi:10.1109/TMECH.2007.897253.

López-Delis, A., D. Delisle-Rodríguez, A. C. Villa-Parra, and T. Bastos-Filho. 2015. Knee motion pattern classification from trunk muscle based on sEMG signals. In: 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). p. 2604–2607.

Lu, L., J. Yan, and C. W. de Silva. 2016. Feature selection for ECG signal processing using improved genetic algorithm and empirical mode decomposition. *Measurement*. 94:372–381. doi:10.1016/j.measurement.2016.07.043.

Ma, S., and J. Huang. 2008. Penalized feature selection and classification in bioinformatics. *Brief. Bioinformatics*. 9:392–403. doi:10.1093/bib/bbn027.

Matsumura, Y., F. Minoru, and M. Yasue. 2006. Hybrid EMG Recognition System by MDA y PCA. In: IEEE, Sheraton Vancouver Wall Centre Hotel, Vancouver, BC, Canadá. p. 7.

- McCool, P., L. Petropoulakis, J. J. Soraghan, and N. Chatlani. 2015. Improved pattern recognition classification accuracy for surface myoelectric signals using spectral enhancement. *Biomedical Signal Processing and Control*. 18:61–68. doi:10.1016/j.bspc.2014.12.001.
- Merlo, A., D. Farina, and R. Merletti. 2003. A Fast and Reliable Technique for Muscle Activity Detection From Surface EMG Signals. *Biomedical Engineering*. 50:316–323. doi:10.1109/TBME.2003.808829.
- Miller, J. D., M. S. Beazer, and M. E. Hahn. 2013. Myoelectric Walking Mode Classification for Transtibial Amputees. *IEEE Transactions on Biomedical Engineering*. 60:2745–2750. doi:10.1109/TBME.2013.2264466.
- Muñoz, J., J. Rivera, and E. Duque. 2008. ANÁLISIS DE COMPONENTES PRINCIPALES E INDEPENDIENTES APLICADOS A REDUCCIÓN DE RUIDO EN SEÑALES ELECTROCARDIOGRAFICAS. *Scientia et Technica Año XIV*. 2:83–88.
- Nazir, M., A. Majid-Mirza, and S. Ali-Khan. 2014. PSO-GA Based Optimized Feature Selection Using Facial and Clothing Information for Gender Classification. *Journal of Applied Research and Technology*. 12:145–152. doi:10.1016/S1665-6423(14)71614-1.
- Omari, F. A., and G. Liu. 2015. Novel hybrid soft computing pattern recognition system SVM–GAPSO for classification of eight different hand motions. *Optik*. 126:4757–4762. doi:10.1016/j.ijleo.2015.08.170.
- Oskoei, M. A., and H. Hu. 2008. Evaluation of support vector machines in upper limb motion classification using myoelectric signal. In: 2008 ICBME.
- Pancholi, S., and A. M. Joshi. 2018. Portable EMG Data Acquisition Module for Upper Limb Prosthesis Application. *IEEE Sensors Journal*. 18:3436–3443. doi:10.1109/JSEN.2018.2809458.
- Parker, P. A., and R. N. Scott. 1986. Myoelectric control of prostheses. *Crit Rev Biomed Eng*. 13:283–310.
- Peng, H., F. Long, and C. Ding. 2005. Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 27:1226–1238. doi:10.1109/TPAMI.2005.159.
- Phinyomark, A., A. Nuidod, P. Phukpattaranont, and C. Limsakul. 2012. Feature Extraction and Reduction of Wavelet Transform Coefficients for EMG Pattern Recognition. *Elektronika ir Elektrotechnika*. 122:27–32. doi:http://dx.doi.org/10.5755/j01.eee.122.6.1816.
- Prasad, M., S. Tripathi, and K. Dahal. 2020. An efficient feature selection based Bayesian and Rough set approach for intrusion detection. *Applied Soft Computing*. 87:105980. doi:10.1016/j.asoc.2019.105980.

Rasheed, S. 2006. A Multiclassifier Approach to Motor Unit Potential Classification for EMG Signal Decomposition [Doctor of Philosophy in Systems Design Engineering]. University of Waterloo, Waterloo, Ontario, Canadá.

Rasool, G., N. Bouaynaya, K. Iqbal, and G. White. 2014. Surface myoelectric signal classification using the AR-GARCH model. *Biomedical Signal Processing and Control*. 13:327–336. doi:10.1016/j.bspc.2014.06.001.

Remeseiro, B., and V. Bolon-Canedo. 2019. A review of feature selection methods in medical applications. *Computers in Biology and Medicine*. 112:103375. doi:10.1016/j.combiomed.2019.103375.

Robnik-Šikonja, M., and I. Kononenko. 2003. Theoretical and Empirical Analysis of ReliefF and RReliefF. *Machine Learning*. 53:23–69. doi:10.1023/A:1025667309714.

Rodríguez, Y., Y. Fernández, R. Bello, and Y. Caballero. 2014. Selección de atributos relevantes aplicando algoritmos que combinan conjuntos aproximados y optimización en colonias de hormigas. *Revista Cubana de Ciencias Informáticas*. 8:79–86.

Rodriguez-Lujan, I., G. Bailador, C. Sanchez-Avila, A. Herrero, and G. Vidal-de-Miguel. 2013. Analysis of pattern recognition and dimensionality reduction techniques for odor biometrics. *Knowledge-Based Systems*. 52:279–289. doi:10.1016/j.knosys.2013.08.002.

Rogers, L. C., and N. J. Bevilacqua. 2010. Organized programs to prevent lower-extremity amputations. *J Am Podiatr Med Assoc*. 100:101–104. doi:10.7547/1000101.

Rossi, M., S. Benatti, E. Farella, and L. Benini. 2015. Hybrid EMG classifier based on HMM and SVM for hand gesture recognition in prosthetics. In: 2015 IEEE International Conference on Industrial Technology (ICIT). p. 1700–1705.

Rothstein, J. M., S. H. Roy, and S. L. Wolf. 2005. MANUAL DEL ESPECIALISTA EN REHABILITACIÓN (Cartoné y bicolor). Editorial Paidotribo.

Russell Esposito, E., and J. M. Wilken. 2014. Biomechanical risk factors for knee osteoarthritis when using passive and powered ankle-foot prostheses. *Clinical Biomechanics*. 29:1186–1192. doi:10.1016/j.clinbiomech.2014.09.005.

Sacco, I. C. N., A. A. Gomes, M. E. Otuzi, D. Pripas, and A. N. Onodera. 2009. A method for better positioning bipolar electrodes for lower limb EMG recordings during dynamic contractions. *J Neurosci Methods*. 180:133–137. doi:10.1016/j.jneumeth.2009.02.017.

Sandoval-Castro, X. Y. 2011. Prótesis de mano 1.0 [Maestría en Ciencias]. Universidad Autónoma de Querétaro, Querétaro. Qro.

Sapsanis, C., G. Georgoulas, A. Tzes, and D. Lymberopoulos. 2013. Improving EMG based classification of basic hand movements using EMD. In: 2013 35th Annual International

Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). p. 5754–5757.

Subbotin, S. 2018. Quasi-Relief Method of Informative Features Selection for Classification. In: 2018 IEEE 13th International Scientific and Technical Conference on Computer Sciences and Information Technologies (CSIT). Vol. 1. p. 318–321.

Sun, Y., and D. Wu. 2008. A RELIEF Based Feature Extraction Algorithm. In: SDM.

Tavakoli, M., C. Benussi, P. Alhais Lopes, L. B. Osorio, and A. T. de Almeida. 2018. Robust hand gesture recognition with a double channel surface EMG wearable armband and SVM classifier. *Biomedical Signal Processing and Control*. 46:121–130. doi:10.1016/j.bspc.2018.07.010.

Toledo-Pérez, D. C., M. A. Martínez-Prado, R. A. Gómez-Loenzo, W. J. Paredes-García, and J. Rodríguez-Reséndiz. 2019. A Study of Movement Classification of the Lower Limb Based on up to 4-EMG Channels. *Electronics*. 8:259. doi:10.3390/electronics8030259.

Vapnik, V., and C. Corinna. 1995. Support-Vector Networks. *Mach Learn*. 20:273–297. doi:10.1007/BF00994018.

Viladot-Voegeli, A. 2003. Anatomía funcional y biomecánica del tobillo y pie. *Rev Esp Reumatol*. 30:469–477. doi:13055077.

Wang, H., L. Tan, and B. Niu. 2019. Feature selection for classification of microarray gene expression cancers using Bacterial Colony Optimization with multi-dimensional population. *Swarm and Evolutionary Computation*. 48:172–181. doi:10.1016/j.swevo.2019.04.004.

Wang, Y., and F. Makedon. 2004. Application of Relief-F feature filtering algorithm to selecting informative genes for cancer classification using microarray data. In: *Proceedings. 2004 IEEE Computational Systems Bioinformatics Conference, 2004. CSB 2004*. p. 497–498.

Waris, A., I. K. Niazi, M. Jamil, O. Gilani, K. Englehart, W. Jensen, M. Shafique, and E. N. Kamavuako. 2018. The effect of time on EMG classification of hand motions in able-bodied and transradial amputees. *Journal of Electromyography and Kinesiology*. 40:72–80. doi:10.1016/j.jelekin.2018.04.004.

Wei, B., W. Zhang, X. Xia, Y. Zhang, F. Yu, and Z. Zhu. 2019. Efficient Feature Selection Algorithm Based on Particle Swarm Optimization With Learning Memory. *IEEE Access*. 7:166066–166078. doi:10.1109/ACCESS.2019.2953298.

Weston, J., A. Elisseeff, G. BakIr, and F. Sinz. *The Spider*.

Wiesław, P. 2019. Tree-based generational feature selection in medical applications. *Procedia Computer Science*. 159:2172–2178. doi:10.1016/j.procs.2019.09.391.

Xiong, B., Y. Li, M. Huang, W. Shi, M. Du, and Y. Yang. 2019. Feature Selection of Input Variables for Intelligence Joint Moment Prediction Based on Binary Particle Swarm Optimization. *IEEE Access*. 7:182289–182295. doi:10.1109/ACCESS.2019.2959064.

Xue, Y., T. Tang, W. Pang, and A. X. Liu. 2020. Self-adaptive parameter and strategy based particle swarm optimization for large-scale feature selection problems with multiple classifiers. *Applied Soft Computing*. 88:106031. doi:10.1016/j.asoc.2019.106031.

Zafra, A., M. Pechenizkiy, and S. Ventura. 2010. Feature selection is the ReliefF for multiple instance learning. In: 2010 10th International Conference on Intelligent Systems Design and Applications. p. 525–532.

Zhang, J., Y. Xiong, and S. Min. 2019. A new hybrid filter/wrapper algorithm for feature selection in classification. *Analytica Chimica Acta*. 1080:43–54. doi:10.1016/j.aca.2019.06.054.

Zhang, Y., D. Gong, X. Gao, T. Tian, and X. Sun. 2020. Binary differential evolution with self-learning for multi-objective feature selection. *Information Sciences*. 507:67–85. doi:10.1016/j.ins.2019.08.040.

Zhou. 2010. Signal Classification Method Based on Support Vector Machine and High-Order Cumulants. *Wireless Sensor Network*. 2. doi:10.4236/wsn.2010.21007.