Generación de señales mioeléctricas para rehabilitación de miembros inferiores mediante lógica difusa y machine learning.

Carlos Alberto Bacilio Díaz

2026



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Generación de señales mioeléctricas para rehabilitación de miembros inferiores mediante lógica difusa y machine learning

Tesis

Que como parte de los requisitos para obtener el Grado de

Maestro en Ciencias en Inteligencia Artificial

Presenta

Carlos Alberto Bacilio Díaz

Dirigido por:
Dr. András Takács

Querétaro, Qro. a 23 de Octubre de 2026

REPOSITORIO INSTITUCIONAL DGBSDI-UAQ

La presente obra está bajo la licencia:
https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es

CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

Compartir — copiar y redistribuir el material en cualquier medio o formato

La licenciante no puede revocar estas libertades en tanto usted siga los términos de la licencia

Bajo los siguientes términos:

Atribución — Usted debe dar crédito de manera adecuada , brindar un enlace a la licencia, e indicar si se han realizado cambios . Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que usted o su uso tienen el apoyo de la licenciante.

NoComercial — Usted no puede hacer uso del material con propósitos comerciales .

SinDerivadas — Si remezcla, transforma o crea a partir del material, no podrá distribuir el material modificado.

No hay restricciones adicionales — No puede aplicar términos legales ni medidas tecnológicas que restrinjan legalmente a otras a hacer cualquier uso permitido por la licencia.

Avisos:

No tiene que cumplir con la licencia para elementos del material en el dominio público o cuando su uso esté permitido por una excepción o limitación aplicable.

No se dan garantías. La licencia podría no darle todos los permisos que necesita para el uso que tenga previsto. Por ejemplo, otros derechos como publicidad, privacidad, o derechos morales pueden limitar la forma en que utilice el material.

Universidad Autónoma de Querétaro

Facultad de Ingeniería

Maestría en Ciencias en Inteligencia Artificial

Generación de señales mioeléctricas para rehabilitación de miembros inferiores mediante lógica difusa y machine learning.

Tesis

Que como parte de los requisitos para obtener el Grado de

Maestro en Ciencias en Inteligencia Artificial

Presenta

Carlos Alberto Bacilio Díaz

Dirigido por

Dr. András Takács

Dr. András Takács
Presidente

Dr. Saúl Tovar Arriaga
Secretario

Dr. Juvenal Rodríguez Reséndiz
Vocal

Dr. Marcos Romo Aviles
Suplente

Dr. Edgar Alejandro Rivas Araiza
Suplente

Centro Universitario, Querétaro, Qro. México
Octubre 2026

Quiero dedicar este trabajo a mi madre que está en el cielo y a mi padre.
¡Lo logramos!

Agradecimientos

Quiero agradecer a la **Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI)** por haberme otorgado la beca para iniciar este posgrado.

A la **Universidad Autónoma de Querétaro** por permitirme utilizar el espacio, los recursos y el apoyo durante mi estancia en la institución.

Al **Dr. Andras Takacs** y al **Dr. Saúl Tovar Arriaga**, por su paciencia, su guía y porque sin su apoyo no hubiera podido terminar mi estancia académica.

A mis padres por haberme educado, impulsado a seguir adelante y brindarme su apoyo incondicional, especialmente en los momentos difíciles.

A mi hermana y sobrinos, por apoyarme y alentarme en este proceso.

Abreviaturas y siglas

- **sEMG** – Señal electromiografica
- **EMG** – Electromiografia
- **QDA** – Análissi Discriminante Cuadrático
- **NB** – Naïves Bayes
- **SVM** – Máquina de vectores de soporte
- **KNN** – K vecinos más cercanos
- **NARXNN** – Red Neuronal autoregresiva con entradas exógenas
- **SENIAM** – Surface EMG for Non-Invasive Assessment of Muscles
- **IED** – Distancia entre electrodos
- **ELA** – Esclerosis lateral amiotrófica
- **LDA** – Análisis Discriminante Lineal

Resumen

La debilidad muscular en extremidades inferiores representa una barrera para la marcha segura y autónoma. La detección oportuna de anomalías mioeléctricas y la respuesta de estimulación adecuada son esenciales para asistir el movimiento y prevenir caídas. Se planteó desarrollar un sistema inteligente capaz de identificar movimientos anómalos durante la marcha y generar voltajes de estimulación controlados. El objetivo consistió en diseñar un sistema modular basado en aprendizaje automático y lógica difusa para clasificar señales electromiográficas (sEMG por sus siglas en inglés) y asistir la marcha mediante activación muscular dirigida. Se utilizó una base de datos de señales EMG adquiridas con sensores superficiales durante distintas fases del ciclo de marcha. Las señales fueron preprocesadas, limpiadas y convertidas a vectores de características estadísticas. Posteriormente se aplicaron diversos modelos de clasificación supervisada y se seleccionó el Análisis Discriminante Cuadrático (QDA por sus siglas en inglés) por su desempeño superior con una precisión de 93.33 %. Para el control de estimulación, se implementó un sistema difuso con funciones de pertenencia gaussianas que asigna voltajes de salida en función de la intensidad de la anomalía detectada. Se establecieron reglas simples para estimular el músculo tibial anterior ante movimientos dorsales y el músculo de la pantorrilla en caso de movimientos plantares. La validación incluyó simulaciones con entradas aleatorias en el rango $[-5, 5]$ representando variabilidad fisiológica. Se generaron voltajes diferenciados por fase de marcha y se calculó el error cuadrático medio (RMSE por sus siglas en inglés), obteniendo un valor de 21.21 % para el tibial anterior y 0.57 % para la pantorrilla. Los resultados sugieren que la combinación de modelos clasificadores precisos con sistemas difusos puede asistir de manera eficiente a individuos con alteraciones musculares, generando respuestas adaptativas durante la marcha.

Palabras clave: señales electromiográficas, aprendizaje automático, lógica difusa, estimulación muscular, marcha.

Abstract

Muscle weakness in lower limbs limits autonomous gait and increases the risk of falls. Early detection of myoelectric anomalies and adaptive stimulation responses are crucial to support movement. An intelligent system was developed to identify anomalous movements during gait and produce controlled stimulation voltages. The objective was to design a modular system based on machine learning and fuzzy logic to classify EMG signals and assist locomotion through targeted muscle activation. A custom EMG dataset was acquired using surface sensors during different gait phases. Signals were preprocessed, cleaned, and transformed into statistical feature vectors. Several supervised classification models were applied; Quadratic Discriminant Analysis (QDA) showed the best performance with 93.33 % accuracy. A fuzzy control system was implemented with Gaussian membership functions to assign stimulation voltage based on detected anomaly intensity. Simple rules were established to stimulate the tibialis anterior during dorsiflexion and the calf during plantarflexion. Validation included simulations with random inputs in the range $[-5, 5]$ representing physiological variability. Differentiated voltages were generated per gait phase, and root mean square error (RMSE) was computed, yielding 21.21 % for the tibialis anterior and 0.57 % for the calf. Results indicate that the combination of accurate classification models with fuzzy systems can efficiently assist individuals with muscular alterations by generating adaptive responses during gait.
Keywords: electromyographic signals, machine learning, fuzzy logic, muscle stimulation, gait.

Índice

Índice de cuadros

Índice de figuras **1**

1 Introducción **2**
1.1 Señales mio-eléctricas . . . 2
1.2 Planteamiento del problema . . . 2
1.3 Justificación . . . 3

2 Antecedentes **5**

3 Marco teórico **10**
3.1 Señales mioeléctricas . . . 10
3.1.1 Señales electromiográficas . . . 10
3.1.2 Características de las señales electromiográficas . . . 11
3.1.3 Origen y propiedades biofísicas . . . 11
3.1.4 Sensores electromiográficos invasivos y no invasivos . . . 12
3.1.5 Instrumentación y adquisición . . . 13
3.1.5.1 Consideraciones técnicas clave . . . 13
3.1.6 Ubicación específica de sensores en músculos de interés . . . 14
3.1.6.1 Músculo Tibial Anterior . . . 14
3.1.6.2 Músculo Gastrocnemio (Gemelos) . . . 14
3.1.6.3 Recomendaciones de SENIAM . . . 14
3.1.7 Aplicaciones de las señales electromiográficas en rehabilitación 15
3.1.7.1 Enfermedades detectables mediante electromiografía . 15
3.2 Inteligencia artificial . . . 15
3.2.1 Análisis Discriminante Cuadrático (QDA) . . . 16
3.2.2 Naïve Bayes . . . 16
3.2.3 K vecinos mas cercanos . . . 17
3.2.4 Árbol de decisión (decision tree) . . . 17
3.2.5 Máquina de soporte de vectores . . . 17
3.2.5.1 Entrenamiento de un modelo SVM . . . 18
3.2.6 Extracción de características EMG . . . 18
3.2.7 Sistema difuso . . . 19
3.2.7.1 Fusificación . . . 19
3.2.7.2 Desfusificación . . . 19
3.2.8 Funciones de pertenencia . . . 20
3.2.8.1 Función Gamma . . . 20
3.2.8.2 Función L . . . 21
3.2.8.3 Función Triangular . . . 21
3.2.8.4 Función Trapezoidal . . . 21

3.2.8.5 Función Sigmoide 22
3.2.9 Métricas de evaluación 22

4 Hipótesis **24**

5 Objetivos **25**
5.1 General 25
5.2 Específicos 25

6 Metodología **26**
6.1 Base de Datos 28
6.1.1 Población de estudio 28
6.1.2 Preparación del participante 28
6.1.3 Colocación de sensores 29
6.1.3.1 Músculo tibial anterior 29
6.1.3.2 Músculo gastrocnemio 30
6.1.4 Adquisición de señales 30
6.1.5 Conversión y organización de la base de datos 31
6.1.6 Procesamiento de señales 32
6.1.6.1 Filtrado y normalización 32
6.1.6.2 Depuración de muestras 33
6.1.6.3 Extracción de características 34
6.2 Entrenamiento y Comparativa de Modelos de Inteligencia Artificial 34
6.2.1 Modelos evaluados 34
6.2.2 Métricas de evaluación 34
6.2.3 Clasificación del tipo de movimiento 34
6.2.4 Detección de asimetría muscular 34
6.2.5 Selección y justificación de modelos 35
6.3 Sistema de Control Difuso 35
6.3.1 Variables del sistema 35
6.3.2 Funciones de membresía 35
6.3.2.1 Entrada 1: Intensidad 35
6.3.2.2 Entrada 2: Umbral de dolor 36
6.3.2.3 Salida: Voltaje 36
6.3.3 Reglas difusas 36
6.3.4 Generación de estimulación eléctrica 36

7 Resultados y discusión **37**
7.1 Base de Datos 37
7.2 Población de estudio 37
7.3 Preparación del participante 37
7.4 Colocación de sensores 37
7.4.1 Músculo tibial anterior 37

7.4.2 Músculo gastrocnemio 37
7.5 Adquisición de señales 38
7.6 Conversión y organización de la base de datos 38
7.7 Procesamiento de señales 38
7.7.1 Filtrado y normalización 38
7.7.2 Depuración de muestras 38
7.7.3 Extracción de características 39
7.8 Entrenamiento y Comparativa de Modelos de Inteligencia Artificial 39
7.8.1 Modelos evaluados 40
7.8.2 Métricas de evaluación 40
7.9 Clasificación del tipo de movimiento 40
7.9.1 Resultados de validación 40
7.9.2 Resultados de prueba 40
7.10 Detección de asimetría muscular 41
7.11 Selección y justificación de modelos 42
7.12 Sistema de Control Difuso 42
7.12.1 Variables del sistema 42
7.12.2 Funciones de membresía 42
7.12.3 Entrada 1: Intensidad 42
7.12.4 Entrada 2: Umbral de dolor 43
7.12.5 Salida: Voltaje 43
7.13 Reglas difusas 43
7.14 Generación de estimulación eléctrica 43
7.15 Evaluación mediante RMSE 43
7.16 Visualización de la estimulación por fase 44

8 Conclusiones **47**
8.1 Discusión general de los resultados 47

Referencias bibliográficas **49**

9 Anexos **53**

Índice de cuadros

2.1 Resumen de investigaciones relacionadas con señales electromiográficas 8
2.2 Ventajas y limitaciones de las investigaciones analizadas 9
3.1 Comparación entre electromiografía invasiva y superficial 13
7.1 Características de los registros utilizados en el estudio. 38
7.2 Resultado de la depuración de la base de datos. 39
7.3 Características extraídas de las señales mioeléctricas. 39
7.4 Comparación de modelos para la clasificación del tipo de movimiento. . 40
7.5 Resultados de validación del modelo Naive Bayes. 41

7.6 Resultados de prueba del modelo Naive Bayes. 41
7.7 Comparación de modelos para la detección de asimetría muscular. . . . 41
7.8 Matriz de confusión del modelo QDA. 42
7.9 Reglas del sistema de control difuso. 43
7.10 Resultados de la evaluación del controlador mediante RMSE. 44

Índice de figuras

3.1 Función de pertenencia Gamma. 20
3.2 Función de pertenencia L. 21
3.3 Función Triangular. 21
3.4 Función Trapezoidal. 22
3.5 Función Sigmoide. 22
6.1 Diagrama general del sistema propuesto. 27
6.2 Materiales utilizados para la adquisición de datos. 29
6.3 Colocación de sensores en el músculo tibial anterior. 30
6.4 Colocación de sensores en el músculo gastrocnemio. 30
6.5 Señal electromiográfica adquirida durante las pruebas experimentales. . 31
6.6 Representación matricial de las señales electromiográficas procesadas. . 32
6.7 Comparativa entre señales sin filtrar y señales filtradas. 33
7.1 Simulación de estimulación en apoyo inicial. 45
7.2 Simulación en fase de apoyo medio. No se requiere estimulación. 45
7.3 Simulación fase de despegue. 46
7.4 Simulación fase de balanceo. 46

1. Introducción

1.1. Señales mio-eléctricas

Las señales mio-eléctricas (sEMG, por sus siglas en inglés) son potenciales eléctricos generados por la actividad neuro-muscular voluntaria o involuntaria, medibles en la superficie de la piel mediante electrodos superficiales. Estas señales proporcionan información crucial sobre la activación de los músculos y permiten inferir el estado funcional del sistema neuromuscular.

En el caso específico de las extremidades inferiores, las sEMG de músculos como el tibial anterior y pantorrilla permiten evaluar patrones de marcha y posibles desbalances o anomalías entre ambas piernas. Esto es especialmente relevante en aplicaciones de rehabilitación, ortesis activas, o diagnóstico temprano de trastornos motores.

Las sEMG permiten estudiar el comportamiento de los músculos a través de la actividad bioeléctrica generada por las unidades motoras. Son una herramienta esencial en estudios clínicos y biomecánicos para evaluar el estado funcional de un músculo en reposo y durante la contracción voluntaria [1].

En el caso de los miembros inferiores, el análisis mioeléctrico se ha empleado comúnmente para caracterizar patrones de marcha, identificar desequilibrios musculares, y guiar terapias de rehabilitación [2]. Los músculos más comúnmente analizados en estos contextos son el tibial anterior y el gastrocnemio, debido a su papel central en la dorsiflexión y la flexión plantar del pie.

1.2. Planteamiento del problema

Uno de cada tres personas en el mundo padece algún trastorno neurológico, según reportes de la Organización Mundial de la Salud en 2021 [3]. Se estima que más de 3 000 millones de personas a nivel mundial presentan al menos una afección neurológica, siendo las más comunes el accidente cerebrovascular, la encefalopatía neonatal, la migraña, la meningitis, la epilepsia, complicaciones neurológicas derivadas de partos prematuros, trastornos del espectro autista y cánceres del sistema nervioso. Adicionalmente, se ha observado que hasta el 60 % de los pacientes con daño neurológico periférico también presentan diabetes mellitus [4], lo cual incrementa las complicaciones motoras y el riesgo de atrofia muscular.

En este contexto los procesos de rehabilitación muscular se vuelven indispensables para restablecer la funcionalidad motora. Sin embargo, los métodos tradicionales de rehabilitación presentan diversas limitaciones: se basan en protocolos generalizados dependen de la supervisión clínica presencial, y no incluyen sistemas que ajusten dinámicamente los estímulos de acuerdo al progreso del paciente.

Diversos estudios han explorado la aplicación de sEMG para desarrollar sistemas de rehabilitación más inteligentes. Se han implementado redes neuronales para clasificar movimientos de la mano con alta precisión [5], y modelos como maquina de soporte vec-

torial (SVM por sus siglas en inglés) o K vecinos más cercanos (KNN por sus siglas en inglés) han sido utilizados para detectar patrones musculares con resultados aceptables [6, 7]. A pesar de estos avances, la mayoría de las investigaciones han sido enfocadas en miembros superiores y utilizan bases de datos controladas en condiciones ideales. Además, pocos estudios han comparado explícitamente señales mioeléctricas entre extremidades (por ejemplo, pierna izquierda vs. derecha) para identificar asimetrías o atrofias.

Por otro lado, los sistemas de control difuso han sido empleados en exoesqueletos y dispositivos de estimulación eléctrica funcional (FES por sus siglas en inglés) con resultados prometedores en la personalización de la respuesta motora [8, 9]. No obstante, su integración con clasificadores EMG en tiempo real para ajustar dinámica-mente, la estimulación sigue siendo escasa en el ámbito clínico.

El problema que se aborda en esta investigación radica en la ausencia de sistemas que:

a. Detecten anomalías mioeléctricas comparando señales entre piernas,

b. Clasifiquen automáticamente el tipo de movimiento realizado,

c. Generen una respuesta de estimulación eléctrica mediante un controlador difuso adaptativo.

Muchos estudios se han enfocado en la clasificación de movimientos (como dorsiflexión, flexión plantar, etc.) o en el reconocimiento de intenciones de marcha usando modelos de aprendizaje automático. Otros trabajos se han enfocado en el diseño de controladores difusos para activar dispositivos de asistencia basados en la detección de movimiento. Sin embargo, la mayoría de estas propuestas no se enfocan en la detección de anomalías musculares entre piernas, ni combinan análisis discriminante, clasificación probabilística y control inteligente dentro de un solo sistema adaptativo.

Este trabajo propone un sistema que combine técnicas de clasificación como el análisis discriminante cuadrático (QDA por sus siglas en inglés) y Naïve Bayes, junto con un módulo de control difuso, para asistir de forma personalizada la rehabilitación muscular en pacientes con daño neurológico periférico.

1.3. Justificación

A pesar de los avances en adquisición, procesamiento y análisis de sEMG de superficie, la detección automatizada de anomalías funcionales sigue representando un reto importante. Particularmente, el análisis comparativo entre extremidades, por ejemplo, entre una pierna sana y una pierna con afectación neurológica o muscular, presenta dificultades técnicas asociadas a la variabilidad fisiológica, la necesidad de segmentación precisa y el manejo de ruido inherente en las señales biomédicas [10].

Diversos trabajos han demostrado éxito en la clasificación de movimientos específicos (como flexión dorsal o plantar) mediante técnicas de aprendizaje automático, incluyendo

SVM, redes neuronales artificiales (ANN por sus siglas en inglés), y algoritmos basados en KNN [5, 7]. Sin embargo, estas estrategias comúnmente se enfocan en una sola pierna, y son diseñadas para tareas de clasificación aisladas sin evaluar simetrías musculares o detectar signos de atrofia o disfunción inter-lateral.

Por otro lado, el control adaptativo en sistemas de rehabilitación muscular mediante lógica difusa ha mostrado efectividad en personalizar la estimulación eléctrica funcional (FES), ya que permite definir reglas difusas que imitan el razonamiento humano en condiciones de incertidumbre [8, 9]. No obstante, los sistemas actuales de FES inteligentes no integran comparadores de activación muscular entre extremidades, lo cual es clave en contextos clínicos como accidentes cerebrovasculares, neuropatías periféricas y síndromes de desuso.

Este proyecto propone un sistema híbrido que integra:

- Algoritmos de clasificación de señales mioeléctricas orientados a la detección de anomalías inter-laterales, utilizando QDA y Naïve Bayes;
- Un módulo de control difuso diseñado para activar dispositivos de estimulación muscular de acuerdo con las decisiones clasificadas y contextualizadas por comparación bilateral;
- Un enfoque clínicamente relevante que permite evaluar no solo el tipo de movimiento, sino también la integridad funcional de las extremidades de forma personalizada.

La novedad de esta propuesta radica en combinar técnicas estadísticas supervisadas con lógica difusa para detectar asimetrías mioeléctricas y generar una respuesta terapéutica adaptativa. Esta integración constituye un avance significativo frente a los modelos actuales centrados exclusivamente en clasificación unipodal o estimulación predefinida, y abre nuevas posibilidades en la rehabilitación neuromuscular automatizada.

2. Antecedentes

El uso de señales electromiográficas superficiales (sEMG) para la identificación de patrones musculares ha experimentado un crecimiento significativo durante los últimos años debido a su potencial aplicación en sistemas de rehabilitación, prótesis inteligentes, exoesqueletos y dispositivos de asistencia motriz-motora. Estas señales contienen información relacionada con la activación neuromuscular y permiten inferir la intención de movimiento de una persona mediante técnicas de procesamiento digital y algoritmos de inteligencia artificial.

Uno de los trabajos más relevantes en el área de rehabilitación de miembros superiores fue desarrollado por Amrani et al. [11], quienes propusieron un sistema inteligente para asistir ejercicios de deslizamiento de tendones de la mano mediante el reconocimiento automático de patrones mioeléctricos. El objetivo principal fue facilitar los procesos de rehabilitación reduciendo la supervisión constante del terapeuta. Para ello, se adquirieron señales EMG provenientes de músculos involucrados en los movimientos de los dedos y la muñeca. Posteriormente, las señales fueron procesadas mediante técnicas de extracción de características temporales y utilizadas como entrada para una red neuronal artificial multicapa (MLP). Los resultados mostraron una precisión de clasificación del 95.11 % y un tiempo promedio de respuesta de aproximadamente 300 ms. Aunque los resultados fueron prometedores, la validación se realizó únicamente en individuos sanos, lo que limita la extrapolación de los resultados hacia pacientes con alteraciones neuromusculares. Sin embargo, este trabajo demuestra la viabilidad de emplear redes neuronales para identificar patrones musculares asociados a movimientos específicos.

En el ámbito de la identificación de patrones durante la marcha humana, Nasr et al. [12] investigaron el uso de señales EMG para reconocer las distintas fases del ciclo de marcha. Su propuesta consistió en comparar el desempeño de redes bayesianas dinámicas y análisis discriminante lineal (LDA) para clasificar los estados de locomoción. Las señales fueron obtenidas mediante sensores de superficie colocados sobre músculos de las extremidades inferiores y posteriormente acondicionadas mediante amplificación y filtrado de ruido. Los autores reportaron que ambos métodos fueron capaces de identificar adecuadamente los patrones musculares asociados al movimiento; sin embargo, presentaron dificultades para modelar de forma precisa las transiciones entre diferentes estados de marcha. Esta limitación resulta especialmente importante en aplicaciones de control en tiempo real, donde los cambios rápidos entre movimientos requieren respuestas inmediatas del sistema de clasificación.

Por otra parte, Simonetti et al. [13] desarrollaron una metodología automatizada para estudiar la activación muscular durante la marcha humana utilizando electromiografía de alta densidad. El sistema empleó 64 electrodos secos distribuidos estratégicamente sobre las extremidades inferiores con el objetivo de capturar información detallada sobre la actividad muscular. Para el procesamiento de las señales se implementó un filtro Butterworth de segundo orden con retardo cero, permitiendo reducir el ruido sin alterar significativamente la información temporal. Los resultados permitieron

identificar con precisión los músculos que participan en cada fase de la marcha y cuantificar su nivel de activación. Aunque el estudio no estuvo enfocado directamente en la clasificación automática mediante algoritmos de inteligencia artificial, proporcionó una base importante para comprender los patrones fisiológicos que posteriormente pueden utilizarse como variables de entrada en modelos predictivos.

La incorporación de técnicas de aprendizaje automático en sistemas de asistencia motriz ha permitido mejorar significativamente la capacidad de reconocimiento de movimientos. Ayachi et al. [14] evaluaron el desempeño de máquinas de vectores de soporte (SVM) para clasificar movimientos musculares destinados al control de prótesis y exoesqueletos. El estudio utilizó señales EMG obtenidas de diferentes grupos musculares y analizó la capacidad del clasificador para distinguir entre múltiples movimientos funcionales. Los resultados mostraron una exactitud cercana al 90 %, evidenciando la capacidad de las SVM para trabajar con conjuntos de datos de alta dimensionalidad. No obstante, los autores señalaron que el desempeño del sistema disminuye cuando las condiciones de adquisición cambian significativamente entre usuarios o sesiones de entrenamiento, lo que limita su adaptabilidad en aplicaciones clínicas reales.

En una línea similar, José et al. [15] compararon diversos algoritmos de clasificación aplicados a señales electromiográficas, incluyendo árboles de decisión, Random Forest y máquinas de vectores de soporte. El estudio se desarrolló utilizando una base de datos pública compuesta por seis gestos de la mano registrados mediante sensores EMG de superficie. Los resultados mostraron que los modelos basados en aprendizaje profundo y técnicas de ensamble alcanzaron precisiones superiores al 98 %, superando significativamente a los clasificadores tradicionales. Sin embargo, los experimentos estuvieron limitados a movimientos específicos de la mano, por lo que aún existe incertidumbre respecto a su comportamiento en tareas relacionadas con la locomoción humana o el control de músculos de las extremidades inferiores.

Dimitrov et al. [16] exploraron el uso de algoritmos de aprendizaje basados en vecinos más cercanos (KNN) para la identificación de patrones musculares. El sistema incorporó un bioamplificador especializado para mejorar la relación señal-ruido de las señales EMG antes de realizar la clasificación. Los resultados alcanzaron una precisión aproximada del 93 %, demostrando que incluso algoritmos relativamente simples pueden ofrecer desempeños competitivos cuando se dispone de señales adecuadamente acondicionadas. A pesar de ello, la capacidad de generalización del método disminuyó conforme aumentó el número de clases y usuarios evaluados, situación común en algoritmos basados en distancias.

Otra contribución importante fue presentada por Geethanjali et al. [17], quienes implementaron técnicas de alineación temporal dinámica (Dynamic Time Warping, DTW) para reconocer patrones mioeléctricos en aplicaciones de control robótico. La principal ventaja de este enfoque radica en su capacidad para comparar secuencias temporales de distinta duración sin necesidad de sincronización exacta. Los autores reportaron una precisión cercana al 83 %, acompañada de una mejora significativa en los tiempos de respuesta respecto a otros métodos tradicionales. Estas características hacen que DTW sea particularmente atractivo para aplicaciones que requieren procesamiento en tiem-

po real, aunque su desempeño puede verse afectado cuando las señales presentan altos niveles de variabilidad intersujeto.

Más recientemente, Mathew et al. [18] analizaron el impacto de modelos preentrenados y técnicas modernas de aprendizaje automático para la clasificación de movimientos a partir de señales electromiográficas superficiales. El estudio comparó clasificadores como Naïve Bayes, KNN y SVM utilizando bases de datos adquiridas en condiciones de bajo ruido. Los resultados indicaron que los modelos entrenados previamente permiten reducir los tiempos de entrenamiento y mejorar la estabilidad del sistema frente a variaciones en las señales de entrada. No obstante, se observó una disminución en la precisión cuando los modelos fueron aplicados a usuarios con alteraciones motoras, evidenciando la necesidad de incorporar mecanismos de adaptación personalizados.

Dentro del campo específico de la rehabilitación del pie caído, Carvalho et al. [19] propusieron una arquitectura basada en una red neuronal autorregresiva con entradas exógenas (NARXNN) combinada con un controlador proporcional-derivativo. El objetivo fue desarrollar un sistema capaz de ajustar automáticamente la estimulación eléctrica funcional de acuerdo con las características particulares de cada paciente. Los resultados mostraron una mejora de hasta 45.82 % en el patrón de marcha en comparación con condiciones sin asistencia, además de una reducción significativa de la fatiga muscular. La principal contribución de este trabajo radica en la incorporación de mecanismos adaptativos que permiten personalizar el tratamiento en tiempo real, aspecto que representa una tendencia creciente dentro de los sistemas inteligentes de rehabilitación.

En general, los antecedentes revisados demuestran que las señales electromiográficas constituyen una fuente de información confiable para identificar patrones de movimiento y desarrollar sistemas de asistencia motriz. Asimismo, evidencian que algoritmos como SVM, KNN, redes neuronales artificiales, redes profundas, modelos bayesianos y técnicas de alineación temporal han alcanzado resultados satisfactorios en diferentes aplicaciones. Sin embargo, todavía persisten desafíos relacionados con la personalización de los sistemas, la adaptación a diferentes usuarios, la clasificación en tiempo real y la integración con estrategias de control inteligentes. En este contexto, la presente investigación propone la utilización de clasificadores QDA y Naïve Bayes combinados con un sistema de control difuso para identificar patrones musculares asociados al pie caído y generar una estimulación muscular adaptativa, buscando mejorar la precisión, robustez y capacidad de personalización de los sistemas de rehabilitación actuales.

En el ámbito de control adaptativo, Carvalho et al. [19] propusieron una red neuronal autorregresiva con entradas exógenas (NARXNN) combinada con un controlador proporcional-derivativo para corregir el pie caído. Se logró personalización en tiempo real y reducción de la fatiga muscular en un sistema portátil, con mejoras de hasta 45.82 % en el patrón de marcha frente al estado sin corrección.

En conjunto, estas investigaciones han contribuido significativamente al campo de la rehabilitación muscular, especialmente en técnicas de adquisición y clasificación de señales mioeléctricas. No obstante, muchas presentan limitaciones como la falta de personalización, restricción a movimientos específicos, y ausencia de monitoreo continuo.

Cuadro 2.1: Resumen de investigaciones relacionadas con señales electromiográficas

Referencia	Año	Objetivo	Método	Contribución principal
[11]	2017	Asistencia automática en rehabilitación de mano	Red neuronal multicapa (MLP)	Precisión de 95.11 % y respuesta en 300 ms
[15]	2017	Clasificación de movimientos del antebrazo	Aprendizaje automático con características temporales	Reconocimiento de gestos mediante señales sEMG
[14]	2014	Clasificación de fuerza muscular	Análisis estadístico de señales sEMG	Identificación de niveles de esfuerzo muscular
[12]	2021	Revisión de prótesis y exoesqueletos controlados por EMG	Revisión bibliográfica	Estado del arte del control mioeléctrico
[17]	2016	Revisión de prótesis de mano mioeléctricas	Revisión bibliográfica	Análisis de técnicas modernas de control
[13]	2022	Estimación de activación muscular del tobillo	EMG de alta densidad	Uso de 64 electrodos integrados en prenda inteligente
[20]	2018	Extracción y selección de características EMG	Análisis de características	Optimización de sistemas de clasificación
[19]	2021	Corrección del pie caído	NARXNN + Control PD	Mejora del patrón de marcha en tiempo real

El cuadro 2.2 podemos observar una comparativa de este análisis etiquetando como ventaja la precisión y desventaja la limitación del proyecto. Este proyecto busca superar estas barreras mediante la integración de algoritmos clasificadores como QDA y Naïve Bayes junto con control difuso para proporcionar una estimulación muscular precisa, adaptable y en tiempo real.

Cuadro 2.2: Ventajas y limitaciones de las investigaciones analizadas

Referencia	**Año**	**Ventaja principal**	**Limitación**
[11]	2017	Precisión de 95.11 %	Evaluado únicamente en sujetos sanos
[15]	2017	Alta capacidad de clasificación	Aplicación limitada a movimientos del antebrazo
[14]	2014	Clasificación de niveles de fuerza	Estudio basado en simulación
[12]	2021	Amplio análisis del estado del arte	No presenta validación experimental propia
[17]	2016	Comparación de múltiples tecnologías	Limitado a prótesis de mano
[13]	2022	Alta resolución espacial mediante 64 electrodos	Enfoque centrado en estimación muscular
[20]	2018	Optimización de características EMG	No implementa sistemas de control
[19]	2021	Adaptación en tiempo real y mejora del patrón de marcha	Requiere entrenamiento personalizado

3. Marco teórico

3.1. Señales mioeléctricas

3.1.1. Señales electromiográficas

Las señales mioeléctricas, también conocidas como señales electromiográficas (EMG), son registros eléctricos generados por la actividad de las fibras musculares durante los procesos de contracción y relajación. Estas señales se originan a partir de los potenciales de acción producidos por las unidades motoras cuando reciben impulsos provenientes del sistema nervioso central. Una unidad motora está compuesta por una neurona motora y el conjunto de fibras musculares que esta inerva, siendo considerada la unidad funcional básica responsable de la producción de fuerza muscular [21, 22].

Cuando una persona realiza un movimiento voluntario, las neuronas motoras transmiten impulsos eléctricos desde la médula espinal hacia las fibras musculares. Como resultado, se producen procesos de despolarización y repolarización en las membranas celulares de las fibras musculares, generando corrientes eléctricas que se propagan a lo largo del músculo. La suma espacial y temporal de los potenciales de acción de múltiples unidades motoras activas produce una señal electromiográfica que puede ser detectada mediante electrodos colocados sobre la superficie de la piel o mediante electrodos invasivos insertados directamente en el tejido muscular [23].

Las señales electromiográficas proporcionan información relacionada con el nivel de activación muscular y la coordinación neuromuscular durante la ejecución de movimientos. Debido a esta característica, han sido ampliamente utilizadas en aplicaciones de biomecánica, análisis de la marcha, control de prótesis mioeléctricas, interfaces hombre-máquina, rehabilitación física y sistemas de asistencia al movimiento [24]. Asimismo, el análisis de estas señales permite evaluar el comportamiento muscular en diferentes condiciones fisiológicas, facilitando la identificación de patrones asociados a movimientos específicos o posibles alteraciones neuromusculares.

Desde el punto de vista del procesamiento de señales, las señales EMG presentan un comportamiento no estacionario, ya que tanto su amplitud como su contenido frecuencial pueden variar continuamente en función del esfuerzo muscular realizado, la velocidad de ejecución del movimiento, el reclutamiento de unidades motoras, la fatiga muscular y las características anatómicas propias de cada individuo [21]. Esta variabilidad representa uno de los principales desafíos para el desarrollo de sistemas automáticos de clasificación y reconocimiento de patrones basados en señales electromiográficas.

Las señales EMG superficiales suelen presentar amplitudes comprendidas entre algunos microvoltios y pocos milivoltios, dependiendo de factores como la intensidad de la contracción, la profundidad del músculo analizado, la ubicación de los electrodos y las condiciones de adquisición. En términos espectrales, la mayor parte de la energía útil de la señal se concentra entre 20 Hz y 450 Hz, aunque pueden existir componentes de frecuencia fuera de este rango debido a ruido eléctrico, movimiento de los electrodos o interferencias externas [23]. Por esta razón, es habitual aplicar técnicas de acondicio-

namiento y filtrado digital antes de realizar cualquier análisis o proceso de extracción de características.

Adicionalmente, las señales electromiográficas son susceptibles a diversas fuentes de contaminación, entre las que destacan la interferencia de la red eléctrica, el ruido electrónico del sistema de adquisición, los artefactos producidos por el movimiento de los electrodos y la actividad de músculos cercanos, fenómeno conocido como *crosstalk*. Para minimizar el efecto de estas perturbaciones y mejorar la calidad de la información obtenida, se emplean procedimientos de preprocesamiento que incluyen filtrado, rectificación, normalización y segmentación de la señal [25]. Estas etapas permiten obtener representaciones más robustas y adecuadas para su utilización en algoritmos de inteligencia artificial y sistemas de apoyo a la rehabilitación.

3.1.2. Características de las señales electromiográficas

Las señales electromiográficas superficiales representan la suma algebraica de los potenciales de acción generados por múltiples unidades motoras activas dentro de un músculo. Debido a que la activación muscular depende de factores como la intensidad de la contracción, el reclutamiento de unidades motoras y la velocidad de conducción de las fibras musculares, las señales EMG presentan una naturaleza compleja, aleatoria y no estacionaria [21].

La amplitud de una señal electromiográfica superficial suele encontrarse en el rango de los microvoltios hasta algunos milivoltios, dependiendo de factores como el músculo analizado, la distancia entre el electrodo y las fibras musculares activas, así como la intensidad de la contracción realizada por el sujeto [22]. De manera general, un incremento en la fuerza muscular se encuentra asociado con un aumento en la amplitud de la señal debido al reclutamiento progresivo de unidades motoras.

Desde el punto de vista espectral, la mayor parte de la energía de las señales EMG superficiales se concentra entre 20 Hz y 450 Hz, aunque pueden existir componentes de frecuencia superiores dependiendo del sistema de adquisición empleado [23]. Esta característica justifica la utilización de filtros pasa banda durante las etapas de acondicionamiento y procesamiento digital.

Otra propiedad importante es la variabilidad temporal de la señal. Incluso cuando un individuo realiza el mismo movimiento en repetidas ocasiones, pueden presentarse pequeñas variaciones debido a factores fisiológicos, fatiga muscular, cambios en la colocación de los electrodos o diferencias en el reclutamiento neuromuscular. Por esta razón, el procesamiento de señales electromiográficas suele incluir técnicas de normalización, segmentación y extracción de características antes de aplicar algoritmos de clasificación o reconocimiento de patrones.

3.1.3. Origen y propiedades biofísicas

La electromiografía de superficie (sEMG) permite evaluar de manera no invasiva

el comportamiento de los músculos, siendo ampliamente empleada en biomecánica y rehabilitación por su facilidad de aplicación y bajo costo [23]. Esta técnica proporciona acceso directo a los procesos fisiológicos que generan fuerza y movimiento muscular, pero su uso requiere comprensión profunda debido a que factores técnicos, anatómicos y fisiológicos pueden afectar la interpretación de la señal.

3.1.4. Sensores electromiográficos invasivos y no invasivos

La adquisición de señales electromiográficas puede realizarse mediante sensores invasivos o no invasivos, dependiendo del método utilizado para registrar la actividad eléctrica muscular. La selección de una u otra técnica depende de factores como la precisión requerida, el músculo de interés, el nivel de comodidad del sujeto y la aplicación específica del sistema.

Los sensores electromiográficos invasivos emplean electrodos de aguja o de alambre fino que son insertados directamente en el tejido muscular. Este método permite registrar la actividad eléctrica de unidades motoras específicas, proporcionando señales con una elevada resolución espacial y una menor influencia de músculos adyacentes. Debido a estas características, la electromiografía invasiva es utilizada principalmente en aplicaciones clínicas, estudios neurofisiológicos y diagnósticos médicos especializados [21].

Sin embargo, la utilización de sensores invasivos presenta ciertas limitaciones. La inserción de los electrodos puede generar molestias o dolor en el paciente, requiere personal capacitado para su colocación y dificulta la realización de mediciones prolongadas o repetitivas. Además, debido a su carácter invasivo, su uso suele restringirse a entornos clínicos controlados.

Por otra parte, los sensores electromiográficos no invasivos, también conocidos como sensores de electromiografía superficial (sEMG), utilizan electrodos colocados sobre la superficie de la piel para detectar la actividad eléctrica generada por los músculos subyacentes. Esta técnica permite registrar la actividad muscular sin necesidad de procedimientos invasivos, proporcionando una alternativa más cómoda y segura para el usuario [22].

La electromiografía superficial se ha convertido en una de las técnicas más utilizadas en aplicaciones de rehabilitación, análisis biomecánico, control de prótesis, interfaces hombre-máquina y sistemas de reconocimiento de movimientos. Su facilidad de implementación, bajo costo y capacidad para realizar adquisiciones en tiempo real la convierten en una herramienta adecuada para sistemas inteligentes basados en señales biológicas.

No obstante, las señales obtenidas mediante sensores superficiales pueden verse afectadas por diversas fuentes de ruido, como la interferencia electromagnética, el movimiento de los electrodos y la actividad de músculos cercanos, fenómeno conocido como *crosstalk*. Por esta razón, es necesario aplicar técnicas de acondicionamiento y procesamiento digital que permitan mejorar la calidad de la señal antes de realizar cualquier análisis o proceso de clasificación.

En la presente investigación se emplearon sensores electromiográficos superficiales debido a su naturaleza no invasiva, facilidad de uso y capacidad para registrar la actividad muscular de los músculos tibial anterior y gastrocnemio durante la ejecución de movimientos funcionales. Esta elección permitió adquirir señales electromiográficas de forma segura y confortable para los participantes, facilitando la construcción de la base de datos utilizada para el entrenamiento y evaluación de los modelos de inteligencia artificial desarrollados.

Cuadro 3.1: Comparación entre electromiografía invasiva y superficial

Característica	EMG invasiva	EMG superficial (sEMG)
Método de adquisición	Electrodos de aguja o alambre	Electrodos sobre la piel
Nivel de invasividad	Alto	Nulo
Comodidad del usuario	Baja	Alta
Resolución espacial	Alta	Moderada
Riesgo de infección	Presente	Inexistente
Aplicaciones	Diagnóstico clínico	Rehabilitación y biomecánica
Costo de implementación	Alto	Bajo
Facilidad de uso	Requiere especialista	Uso relativamente sencillo

3.1.5. Instrumentación y adquisición

Para adquirir señales EMG con fidelidad, se emplean electrodos de superficie de configuración bipolar, usualmente con dos barras paralelas de 10 mm de longitud separadas por 20 mm. Estos deben colocarse en la línea media del vientre muscular, entre la zona de inervación y la unión miotendinosa, alineados con las fibras musculares [26].

El material más utilizado es el Ag/AgCl pregelificado debido a su buena conductividad, baja impedancia y estabilidad. Para evitar artefactos por movimiento y ruido, es necesario fijar los electrodos con cinta adhesiva y filtrar la señal con un paso banda entre 20 y 500 Hz. La señal debe ser muestreada al menos a 1000 Hz para cumplir con el teorema de muestreo y captar adecuadamente las frecuencias útiles del EMG.

Los parámetros más comunes para el análisis temporal son el valor cuadrático medio (RMS por sus siglas en inglés) y el valor rectificado promedio, siendo el RMS el preferido para representar la potencia del músculo en contracciones voluntarias [23].

3.1.5.1. Consideraciones técnicas clave

- Emplear configuración diferencial para minimizar ruido.
- Fijar bien los cables para evitar artefactos de movimiento.
- Usar técnicas como doble diferenciación para reducir interferencia de músculos adyacentes (crosstalk).

3.1.6. Ubicación específica de sensores en músculos de interés

3.1.6.1. Músculo Tibial Anterior

- **Ubicación**: tercio superior de la pierna, entre el borde lateral de la tibia y la línea media.
- **Orientación**: paralela a las fibras musculares.
- **Distancia entre electrodos (IED)**: 20 mm.

El tibial anterior es responsable de la dorsiflexión del pie y es fundamental durante la fase de oscilación en la marcha.

3.1.6.2. Músculo Gastrocnemio (Gemelos)

- **Ubicación**: vientre muscular medial y/o lateral, en el tercio superior entre la rodilla y el tobillo.
- **Orientación**: paralela a las fibras musculares.
- **IED**: 20 mm.

El gastrocnemio participa en la flexión plantar del tobillo y juega un papel esencial en la propulsión del cuerpo durante la marcha.

3.1.6.3. Recomendaciones de SENIAM

El proyecto SENIAM (Surface EMG for Non-Invasive Assessment of Muscles) ha establecido normas europeas sobre la colocación de electrodos, análisis y procesamiento de la señal sEMG. Se recomienda que los electrodos se coloquen:

- A la mitad entre la zona de inervación más distal y el tendón.
- Alejados de bordes musculares para minimizar interferencia de otros músculos.
- Con orientación paralela a las fibras musculares y una IED de 20 mm.

Estas recomendaciones buscan estandarizar la captación de señales y garantizar la reproducibilidad y validez de los análisis clínicos y experimentales [26].

3.1.7. Aplicaciones de las señales electromiográficas en rehabilitación

Las señales electromiográficas han sido ampliamente utilizadas en aplicaciones de rehabilitación física debido a su capacidad para proporcionar información objetiva sobre el estado funcional del sistema neuromuscular. Entre sus principales aplicaciones se encuentran la evaluación de la actividad muscular, la detección de alteraciones motoras, el análisis de la marcha y el control de dispositivos de asistencia.

En sistemas de rehabilitación asistida, las señales EMG permiten identificar la intención de movimiento del usuario mediante técnicas de procesamiento digital y algoritmos de inteligencia artificial. Esta información puede emplearse para controlar prótesis, exoesqueletos, sistemas de estimulación eléctrica funcional y plataformas de entrenamiento terapéutico [24].

En los últimos años, el uso combinado de señales electromiográficas y técnicas de aprendizaje automático ha permitido desarrollar sistemas capaces de clasificar movimientos específicos, detectar anomalías musculares y generar estrategias de asistencia adaptativa. Estas capacidades han convertido a las señales EMG en una herramienta de gran interés para el diseño de sistemas inteligentes orientados a la rehabilitación motora y al monitoreo de pacientes con alteraciones neuromusculares.

3.1.7.1. Enfermedades detectables mediante electromiografía El uso de sEMG permite dar un diagnóstico no invasiva evaluando la actividad eléctrica de los músculos y los nervios periféricos que los controlan. Esta herramienta es fundamental para identificar la presencia de daño o disfunción muscular o nerviosa, facilitando el diagnóstico de diversas enfermedades neuromusculares y trastornos del sistema nervioso periférico a través de la amplitud y la duración de la señal [27].

Entre las patologías que pueden ser detectadas mediante EMG se encuentran:

- **Esclerosis lateral amiotrófica (ELA)**: La EMG ayuda a determinar la progresión de la enfermedad y la gravedad de la disfunción muscular.
- **Distrofia muscular**: Permite detectar cambios en la actividad eléctrica del músculo antes de la aparición de síntomas clínicos.
- **Síndrome del túnel carpiano**: Contribuye a confirmar el diagnóstico y a determinar la gravedad de la lesión del nervio.
- **Neuropatía periférica**, **miastenia gravis**, **poliomielitis** y **neuropatía diabética**: La EMG es útil para identificar estas y otras enfermedades neuromusculares.

3.2. Inteligencia artificial

La inteligencia artificial (IA), perteneciente a las ciencias de la computación, estudia el diseño de sistemas capaces de realizar tareas que normalmente requieren inteligencia humana [28]. Se divide en áreas como inteligencia artificial general, aprendizaje

automático (machine learning) y aprendizaje profundo (deep learning). Estas se clasifican por tipo de aprendizaje (supervisado, no supervisado, por refuerzo), por función humana, técnicas de búsqueda, lógica simbólica, programación genética, enjambres, y planeación heurística.

3.2.1. Análisis Discriminante Cuadrático (QDA)

El Análisis Discriminante Cuadrático es un método de clasificación supervisado que extiende el Análisis Discriminante Lineal (LDA por sus siglas en inglés) al permitir que cada clase tenga su propia matriz de covarianza. Esto habilita la detección de fronteras de decisión no lineales entre clases [29]. A diferencia de LDA, que supone una matriz de covarianza común, QDA modela las clases con mayor flexibilidad, ajustándose mejor a conjuntos de datos donde las distribuciones varían entre categorías.

Este enfoque se basa en estimar la probabilidad de que una observación pertenezca a una clase específica, considerando una distribución gaussiana multivariada para cada clase. La función discriminante toma una forma cuadrática, lo que permite capturar mejor la varianza de cada grupo [30].

Las ventajas principales de QDA incluyen:

- Mayor precisión en contextos donde las clases no son linealmente separables.
- Capacidad de modelar clases con distintas dispersiones y orientaciones.

Entre sus limitaciones se encuentra la necesidad de un mayor número de muestras para estimar múltiples matrices de covarianza, lo cual puede afectar su rendimiento si los datos son escasos.

3.2.2. Naïve Bayes

El clasificador Naïve Bayes (NB) es un modelo probabilístico basado en el teorema de Bayes, que calcula la probabilidad de que una observación pertenezca a una clase, asumiendo independencia condicional entre características dado el valor de la clase [31].

Su fórmula general es:

$$P(C_k|X) = \frac{P(X|C_k) \cdot P(C_k)}{P(X)} \tag{3.1}$$

Donde:

- $P(C_k|X)$ es la probabilidad posterior.
- $P(X|C_k)$ es la verosimilitud.
- $P(C_k)$ es la probabilidad a priori.
- $P(X)$ es la probabilidad de la evidencia.

Aunque el supuesto de independencia rara vez se cumple completamente, en la práctica NB suele tener un rendimiento notable, especialmente en clasificación de texto y problemas con muchas características. Su simplicidad computacional permite un entrenamiento rápido, y su capacidad de generalización lo hace competitivo incluso frente a modelos más complejos [32].

3.2.3. K vecinos mas cercanos

El algoritmo k vecinos mas cercanos (KNN por sus siglas en inglés) es un clasificador que se emplea en actualmente en machine learning, en el area de aprendizaje supervisado, este clasifica predice sobre la agrupación de un punto de datos individual. Este método almacena solamente un conjunto de datos de entrenamiento sin someterse a una fase de entrenamiento. En breves palabras, el algoritmo KNN nos permite identificar los vecinos mas cercanos, para esto se realiza una medición de puntos, el que se utilizó fue distancia Manhattan. La ecuacion (3.2) muestra la distancia entre m cantidad de puntos. [33]

$$d(x, y) = \sum_{i=1}^{m} |x_i - y_i| \tag{3.2}$$

3.2.4. Árbol de decisión (decision tree)

El árbol de decisión es un algoritmo utilizado en ML, es parte del área de aprendizaje supervisado, se utiliza desde las tareas de clasificación hasta de regresión. Tiene una estructura jerárquica, que consiste en un nodo raíz, ramas, nodos internos y nodos de hoja. Los árboles de decisión inician con un nodo raíz, sin ninguna rama entrante, y la salida de este nodo se comunica con nodos internos, a estos nodos se les conoce como nodos decisión, estos nodos evaluan y forman subconjuntos homogéneos, cuyo nombre se le asigna como nodos hojas o nodos terminales, estos contienen todos los resultados posibles dentro del conjunto de datos.

3.2.5. Máquina de soporte de vectores

Las Máquinas de Soporte de Vectores (SVM, por sus siglas en inglés) son clasificadores lineales o no lineales ampliamente utilizados en problemas de clasificación y regresión. Son particularmente efectivas cuando el número de dimensiones es alto, como ocurre con señales EMG [34].

Cuando los patrones de datos no son linealmente separables en el espacio de entrada, las SVM utilizan funciones kernel para realizar una transformación implícita hacia un espacio de características de mayor dimensión, en el cual los datos pueden separarse mediante un hiperplano lineal. Este mecanismo, denominado truco del kernel (kernel trick), evita el costo computacional asociado a la transformación explícita de los datos. La efectividad del modelo depende en gran medida de la función kernel seleccionada,

siendo las más empleadas el kernel lineal, polinomial, de función de base radial (RBF) y sigmoidal. Cada una de estas funciones permite capturar distintos niveles de complejidad y relaciones no lineales presentes en los datos, por lo que su elección debe realizarse de acuerdo con las características del problema a resolver [35].

3.2.5.1. Entrenamiento de un modelo SVM

a. Etiquetar: asignar una clase a cada observación según el gesto o movimiento.

b. Dividir los datos: entrenamiento (70 %) y prueba (30 %).

c. Escalar: normalizar los valores con media cero y desviación unitaria.

3.2.6. Extracción de características EMG

Los sistemas inteligentes para ser optimizados es necesario pasar la información importante y eliminar ruido o información innecesaria, para esto tenemos diferentes dominios, temporal y de frecuencia, cada dominio tiene una técnica necesaria que serán mencionados a continuación.

Dominio temporal

- RMS (Root Mean Square): mide la energía de la señal.
- MAV (Mean Absolute Value): media de los valores absolutos.
- Varianza y Desviación Estándar.
- ZC (Zero Crossing): número de veces que cruza el eje cero.
- WL (Waveform Length): mide la complejidad de la señal.

Dominio frecuencia

- Espectro de potencia, frecuencia media y de pico.
- Transformada de Fourier.

Dominio tiempo-frecuencia

- Transformada Wavelet: permite analizar cambios temporales en diferentes escalas.

3.2.7. Sistema difuso

Un sistema difuso es una metodología computacional basada en la teoría de conjuntos difusos propuesta por Lotfi Zadeh, diseñada para representar y procesar información imprecisa o incierta mediante variables lingüísticas y reglas de inferencia. A diferencia de la lógica clásica, donde una condición únicamente puede ser verdadera o falsa, la lógica difusa permite que una variable pertenezca simultáneamente a varios conjuntos con diferentes grados de pertenencia comprendidos entre 0 y 1.

De acuerdo con Ross [36], un sistema difuso está compuesto por cuatro elementos fundamentales: el proceso de fusificación, una base de reglas difusas, un mecanismo de inferencia y un proceso de desfusificación. Estos componentes trabajan de manera conjunta para transformar datos numéricos de entrada en una salida que represente el comportamiento deseado del sistema.

La principal ventaja de los sistemas difusos radica en su capacidad para modelar procesos complejos mediante conocimiento experto expresado en forma de reglas lingüísticas del tipo "Si-Entonces". Debido a esta característica, han sido ampliamente utilizados en aplicaciones de control, reconocimiento de patrones, sistemas de decisión y procesamiento de señales biomédicas, donde la incertidumbre y la variabilidad de los datos dificultan la utilización de modelos matemáticos convencionales.

3.2.7.1. Fusificación La fusificación constituye la primera etapa dentro de un sistema difuso. Su función consiste en transformar valores numéricos precisos, conocidos como entradas crisp, en grados de pertenencia asociados a diferentes conjuntos difusos. Este proceso permite representar una misma entrada mediante términos lingüísticos como bajo, medio o alto, facilitando la interpretación de la información por parte del sistema de inferencia.

Durante la fusificación se emplean funciones de membresía que asignan a cada valor de entrada un grado de pertenencia comprendido entre 0 y 1. Dependiendo de la aplicación, estas funciones pueden adoptar diversas formas, entre las que destacan las triangulares, trapezoidales, gaussianas y sigmoides. El resultado de esta etapa es un conjunto de valores que indican el grado con el que una entrada pertenece a cada conjunto difuso definido.

En el sistema desarrollado en esta investigación, la fusificación permite transformar las salidas generadas por los modelos de inteligencia artificial en variables lingüísticas que posteriormente son procesadas por el sistema de inferencia difusa para determinar el nivel de estimulación requerido.

3.2.7.2. Desfusificación La desfusificación representa la etapa final de un sistema difuso. Después de que las reglas de inferencia han sido evaluadas y combinadas, se obtiene una salida expresada como un conjunto difuso. Sin embargo, para que esta información pueda ser utilizada por un sistema de control o simulación es necesario convertirla en un valor numérico único.

Ross [36] señala que existen diversos métodos de desfusificación, siendo el método del centroide uno de los más utilizados debido a su capacidad para considerar toda la información contenida en el conjunto difuso resultante. Este método calcula el centro de gravedad del área formada por la función de pertenencia agregada, obteniendo así un valor representativo de la salida del sistema.

La desfusificación permite que las decisiones generadas mediante reglas lingüísticas sean transformadas en acciones cuantificables. En el contexto de esta investigación, este proceso se utiliza para obtener un nivel de estimulación eléctrica simulado a partir de las decisiones tomadas por el sistema difuso, permitiendo evaluar el comportamiento del controlador bajo diferentes condiciones de entrada.

3.2.8. Funciones de pertenencia

Las funciones de pertenencia permiten modelar conceptos imprecisos en lógica difusa. Cada una representa una forma distinta de describir cómo un valor pertenece a un conjunto difuso.

3.2.8.1. Función Gamma La función Gamma es una curva creciente que comienza en un valor bajo y aumenta linealmente hasta alcanzar su punto máximo en m. Representa una transición gradual desde la no pertenencia hasta la pertenencia completa al conjunto difuso, ideal para variables como "temperatura tibia" o "esfuerzo bajo a moderado".

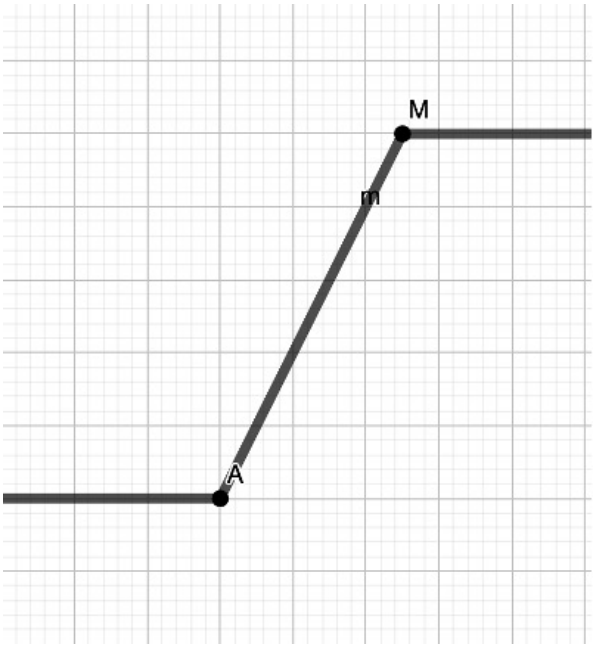


Figura 3.1: Función de pertenencia Gamma.

3.2.8.2. Función L La función L es la inversa de la Gamma. Disminuye linealmente desde un valor máximo hasta cero. Se utiliza cuando se desea representar una disminución progresiva de pertenencia, como por ejemplo en la noción de "dolor tolerable".

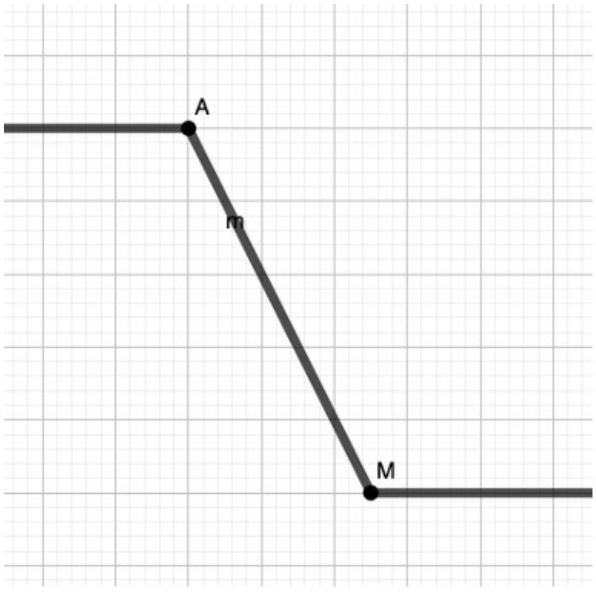


Figura 3.2: Función de pertenencia L.

3.2.8.3. Función Triangular La función triangular tiene forma de pico simétrico. Su valor máximo (modal) se encuentra en el punto medio m, mientras que decrece linealmente hacia cero en los extremos a y b. Es ampliamente usada por su simplicidad para representar valores medios o ideales.

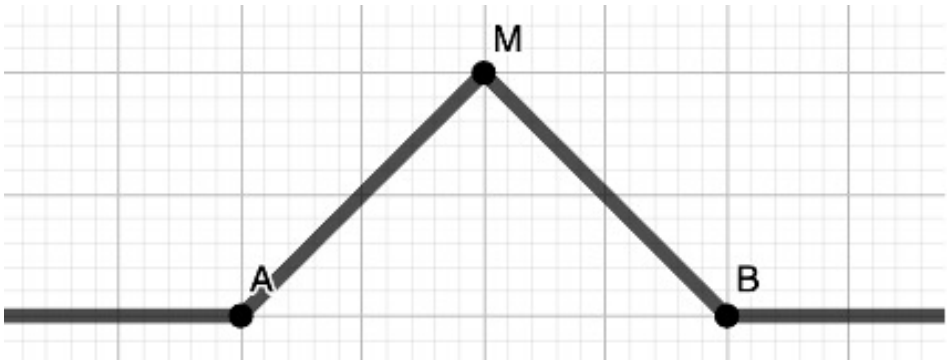


Figura 3.3: Función Triangular.

3.2.8.4. Función Trapezoidal Esta función se define por una meseta central donde la pertenencia es total (valor 1) entre dos puntos b y c, y dos tramos inclinados (creciente y decreciente) en los extremos a y d. Es útil para representar rangos amplios donde un valor intermedio es igualmente válido.

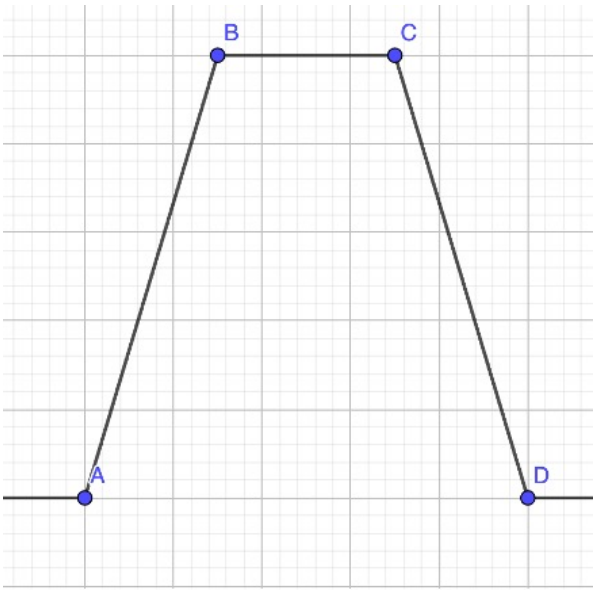


Figura 3.4: Función Trapezoidal.

3.2.8.5. Función Sigmoide La función sigmoide tiene una forma en "S". Su pendiente es suave y su crecimiento asintótico inicia en cero y se aproxima a uno. Es ideal para modelar transiciones suaves y graduales, especialmente en sistemas donde los cambios no son lineales ni abruptos.

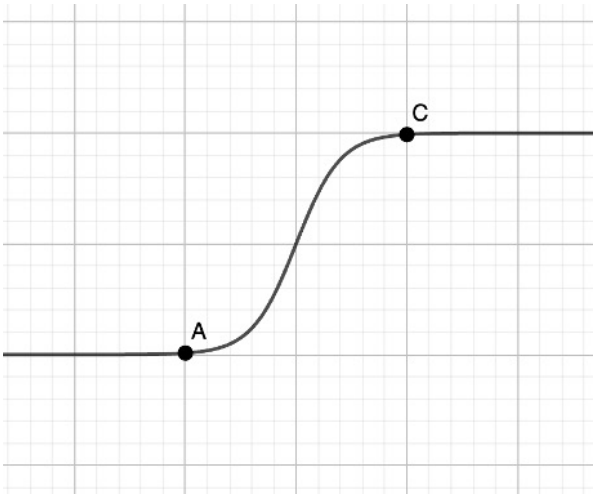


Figura 3.5: Función Sigmoide.

3.2.9. Métricas de evaluación

El Error Cuadrático Medio de la Raíz (RMSE) es una métrica usada para cuantificar la diferencia entre valores predichos y reales:

$$\text{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \tag{3.3}$$

El RMSE penaliza fuertemente los errores grandes y es especialmente útil en sistemas que requieren alta precisión en señales continuas como EMG.

4. Hipótesis

La integración de modelos de aprendizaje automático para la detección de anomalías y clasificación de movimientos musculares, junto con un sistema de control difuso tipo Mamdani, permitirá desarrollar mediante simulación un sistema capaz de identificar variaciones en las señales mioeléctricas de los miembros inferiores y generar una respuesta de estimulación eléctrica adaptativa de acuerdo con la intensidad de la anomalía y el movimiento detectado.

5. Objetivos

5.1. General

Desarrollar un sistema híbrido que detecte anomalías en señales mioeléctricas de las piernas mediante algoritmos de clasificación (QDA y NB) y que utilice un controlador difuso para emitir señales de estimulación adaptativa en procesos de rehabilitación.

5.2. Específicos

a. Adquirir y procesar señales mioeléctricas de ambas piernas durante tareas controladas de movimiento.

b. Diseñar un módulo de extracción de características relevantes (estadísticas y de frecuencia) a partir de las señales EMG.

c. Entrenar y evaluar modelos de clasificación, comparando el desempeño del análisis discriminante cuadrático (QDA) y NB en la detección de anomalías.

d. Diseñar un sistema de control difuso que, con base en la clasificación obtenida, determine la activación adecuada de los músculos mediante estimulación eléctrica.

e. Integrar y validar el sistema completo en un entorno simulado o experimental, midiendo su precisión, sensibilidad y efectividad de respuesta.

6. Metodología

El desarrollo del sistema propuesto se estructuró en diversas etapas metodológicas las cuales permitieron organizar el proceso de adquisición, procesamiento, análisis e interpretación de las sEMG utilizadas en la investigación. Cada una de estas etapas fue diseñada para garantizar la calidad de los datos, la confiabilidad de los modelos de inteligencia artificial y la correcta integración del sistema difuso encargado de generar la respuesta de estimulación adaptativa.

En primer lugar se realizó la adquisición de sEMG superficiales mediante sensores colocados estratégicamente sobre los músculos tibial anterior y gastrocnemio de ambas piernas. La selección de estos músculos se debe a su participación directa en los movimientos de flexión dorsal y flexión plantar del tobillo, los cuales representan movimientos fundamentales durante la marcha humana. Durante esta etapa se establecieron protocolos de adquisición que permitieran registrar señales representativas de cada movimiento, considerando aspectos como la correcta colocación de los electrodos, la reducción de ruido externo y la repetibilidad de las mediciones.

Una vez obtenidas las sEMG, se llevó a cabo una fase de preprocesamiento orientada a mejorar la calidad de la información registrada. Esta etapa incluyó la aplicación de técnicas de filtrado digital para reducir interferencias producidas por el movimiento, el ruido eléctrico y otros artefactos presentes en las señales biológicas. Posteriormente, se realizaron procesos de normalización con el objetivo de homogeneizar la amplitud de las señales y facilitar su comparación entre diferentes registros. Finalmente, se efectuó una depuración de muestras para eliminar segmentos que presentaran inconsistencias o información no representativa, obteniendo así una base de datos confiable para las etapas posteriores.

Con las señales previamente acondicionadas, se procedió a la construcción de la base de datos. Esta fase comprendió la segmentación de las señales en ventanas de análisis y la extracción de características relevantes en los dominios temporal y estadístico. Dichas características permitieron representar el comportamiento muscular mediante un conjunto reducido de variables, facilitando el entrenamiento de los modelos de inteligencia artificial. La base de datos resultante se organizó de acuerdo con los objetivos específicos de cada sistema de clasificación desarrollado en esta investigación.

Posteriormente, se implementaron dos sistemas de clasificación independientes. El primer sistema fue diseñado para detectar posibles asimetrías musculares entre ambas piernas a partir de las sEMG registradas. La finalidad de este modelo fue identificar diferencias en los patrones de activación muscular que pudieran estar asociadas con alteraciones funcionales o desequilibrios durante la ejecución de los movimientos analizados. Para ello, se evaluaron distintos algoritmos de aprendizaje automático utilizando herramientas de comparación automática de modelos, seleccionando aquel que presentó el mejor desempeño de acuerdo con las métricas establecidas.

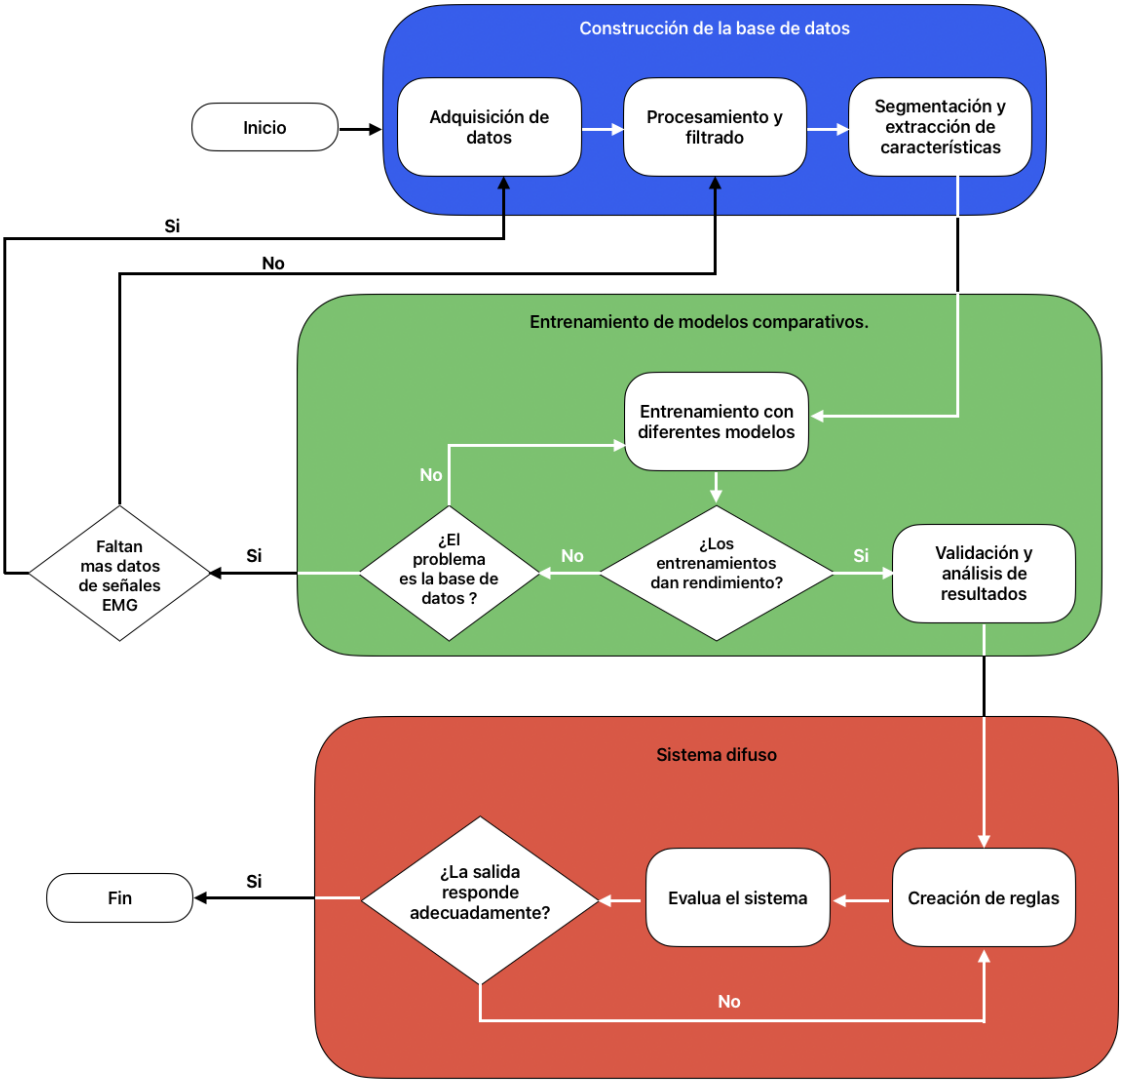


Figura 6.1: Diagrama general del sistema propuesto.

El segundo sistema de clasificación tuvo como objetivo identificar el tipo de movimiento realizado por el usuario. En este caso, el problema se planteó como una clasificación multiclase compuesta por tres categorías: flexión plantar, flexión dorsal y posición neutra. Al igual que en el caso anterior, se realizó una evaluación comparativa de diversos algoritmos de inteligencia artificial con la finalidad de seleccionar el modelo que ofreciera la mejor capacidad de generalización y precisión durante el proceso de clasificación.

Finalmente, las salidas generadas por ambos sistemas de inteligencia artificial fueron

integradas dentro de un sistema de control difuso. Este sistema utilizó como variables de entrada la condición muscular detectada y la posición identificada del pie para determinar el nivel de estimulación eléctrica requerido en cada situación. La lógica difusa permitió incorporar reglas basadas en conocimiento experto, proporcionando una respuesta gradual y adaptable ante diferentes escenarios de operación. Debido a que el alcance de la investigación se limita a un entorno de simulación, la salida del controlador difuso fue evaluada mediante pruebas computacionales orientadas a verificar su comportamiento y consistencia bajo distintas condiciones de entrada.

La realización de este proyecto se resume en el diagrama de flujo mostrado en la figura 6.1. Dicho diagrama se encuentra dividido en tres bloques principales. El primer bloque corresponde a la construcción de la base de datos, abarcando desde la adquisición de las señales electromiográficas hasta las etapas de segmentación y extracción de características necesarias para representar adecuadamente la actividad muscular. El segundo bloque contempla el entrenamiento y evaluación de los diferentes modelos de inteligencia artificial propuestos, permitiendo seleccionar aquellos con mejor desempeño para cada problema de clasificación abordado en la investigación. Finalmente, el tercer bloque corresponde al desarrollo del sistema difuso, donde se define la estructura del controlador, las funciones de membresía y las reglas de inferencia empleadas para generar la respuesta de estimulación adaptativa. En conjunto, estos tres bloques permiten comprender de manera integral la metodología seguida para el diseño, implementación y validación del sistema propuesto.

6.1. Base de Datos

6.1.1. Población de estudio

La población considerada para el estudio estuvo conformada por personas de entre 18 y 60 años con movilidad funcional en al menos un miembro inferior.

La muestra final estuvo integrada por tres mujeres sin antecedentes neuromusculares, con edades comprendidas entre 25 y 36 años y una edad promedio de 29 años, con una desviación estándar de 5.68 años.

Adicionalmente, se incluyó la participación de una mujer de 26 años con alteración muscular en la pierna izquierda, específicamente en la región del músculo tibial anterior, con el propósito de obtener señales asociadas a patrones anómalos.

6.1.2. Preparación del participante

Previo a la adquisición de señales, se solicitó a los participantes asistir con ropa cómoda y evitar el uso de cremas, aceites o sustancias que pudieran afectar la adherencia de los electrodos superficiales.

Asimismo, se verificó la ausencia de vello en la zona de colocación de los sensores para reducir interferencias durante la captura de señales electromiográficas.

Antes de colocar los electrodos, la piel fue limpiada con alcohol etílico para mejorar la conductividad eléctrica y reducir la impedancia entre la superficie cutánea y los

sensores.

Cada participante leyó y firmó un consentimiento informado autorizado para el uso académico de las señales adquiridas. La información recopilada fue anonimizada y únicamente incluyó datos generales como edad y sexo.

6.1.3. Colocación de sensores

Para el desarrollo experimental del sistema se utilizaron dos baterías recargables de litio, una placa de instrumentación para la amplificación de señales electromiográficas, un convertidor DC-DC, una tarjeta de adquisición de datos National Instruments (DAQ), sensores superficiales EMG y cableado de conexión.

El convertidor DC-DC permitió generar voltajes positivos y negativos necesarios para alimentar los amplificadores operacionales de las placas de instrumentación utilizadas en la adquisición de señales sEMG.

Para el procesamiento y análisis de los datos se utilizó una computadora portátil con los programas LabVIEW y Jupyter Notebook.

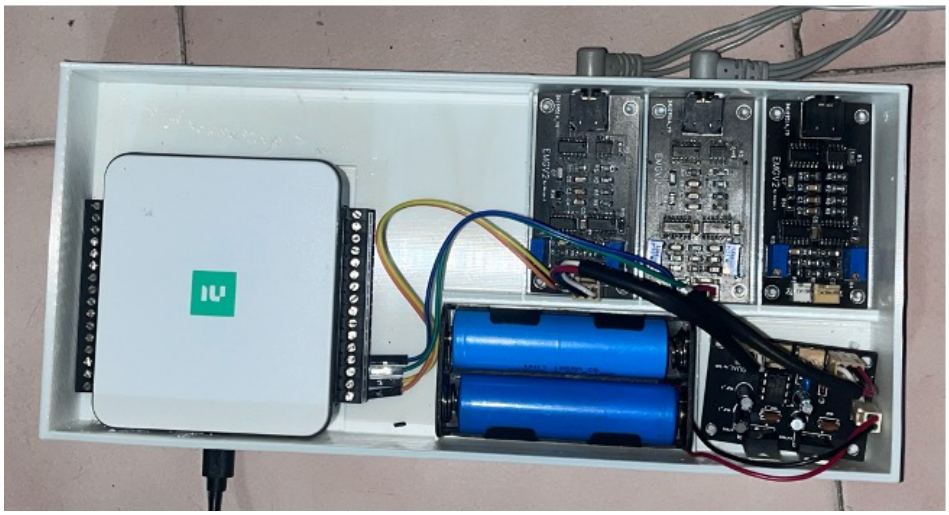


Figura 6.2: Materiales utilizados para la adquisición de datos.

6.1.3.1. Músculo tibial anterior Para la adquisición de señales electromiográficas del músculo tibial anterior, se colocaron dos electrodos activos siguiendo las recomendaciones del protocolo SENIAM, mientras que el electrodo de referencia fue ubicado en la región del tobillo.



Figura 6.3: Colocación de sensores en el músculo tibial anterior.

6.1.3.2. Músculo gastrocnemio En el caso del músculo gastrocnemio, los electrodos activos se colocaron longitudinalmente sobre la masa muscular, utilizando igualmente un electrodo de referencia en la región del tobillo.

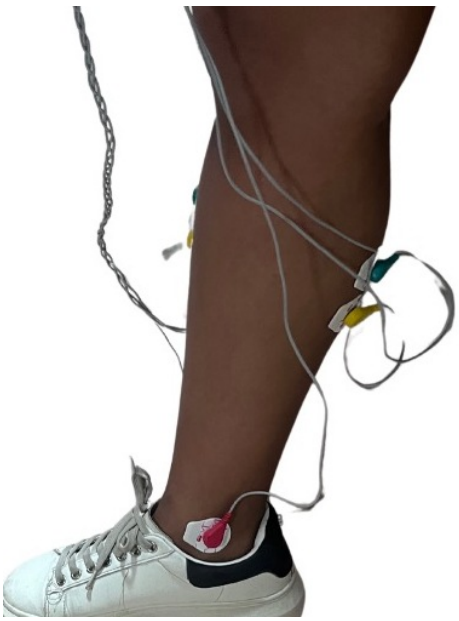


Figura 6.4: Colocación de sensores en el músculo gastrocnemio.

6.1.4. Adquisición de señales

Los participantes realizaron de forma voluntaria tres tipos de movimiento, flexión plantar, flexión dorsal y posición neutra

Cada movimiento fue ejecutado en posición de pie con una duración aproximada de cinco segundos por adquisición. El procedimiento se repitió en ambas piernas, obteniendo múltiples registros por movimiento y por grupo muscular.

Las señales fueron adquiridas mediante LabVIEW utilizando una tarjeta DAQ multicanal y almacenadas inicialmente en formato TDMS.

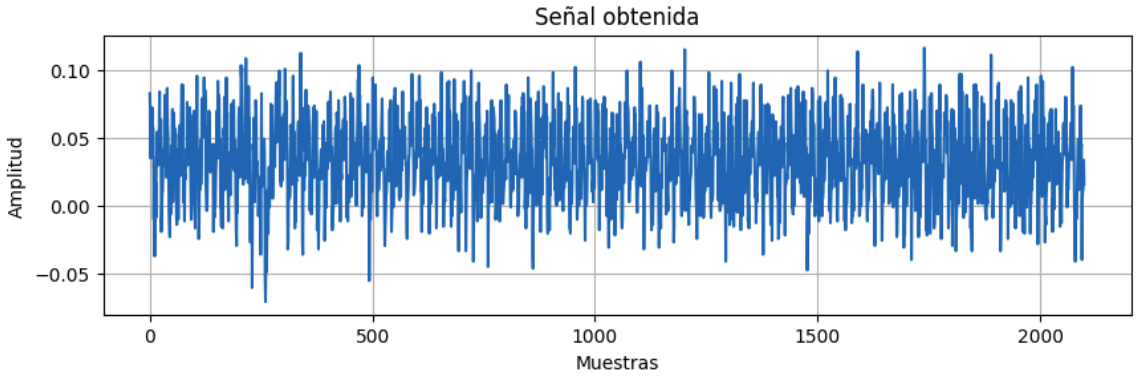


Figura 6.5: Señal electromiográfica adquirida durante las pruebas experimentales.

6.1.5. Conversión y organización de la base de datos

Los archivos TDMS generados durante la adquisición fueron convertidos posteriormente al formato CSV mediante la biblioteca `nptdms` en Python.

Durante este proceso se extrajeron únicamente los canales correspondientes a los músculos tibial anterior y gastrocnemio, facilitando la organización y procesamiento posterior de la base de datos.

Las señales electromiográficas fueron segmentadas en ventanas uniformes de 2100 muestras por canal, correspondientes aproximadamente a cinco segundos de adquisición.

Cada muestra fue almacenada en matrices bidimensionales para facilitar el procesamiento vectorizado y el entrenamiento de los modelos de clasificación.

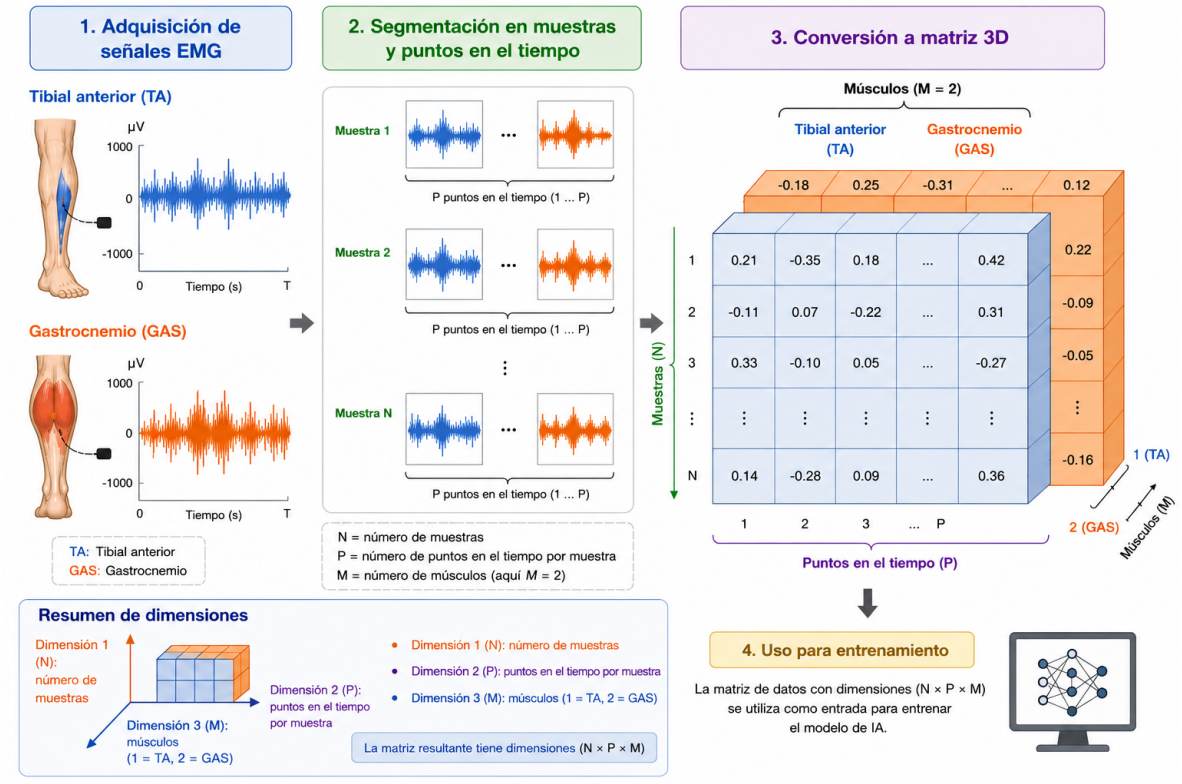


Figura 6.6: Representación matricial de las señales electromiográficas procesadas.

6.1.6. Procesamiento de señales

6.1.6.1. Filtrado y normalización Las señales electromiográficas adquiridas fueron sometidas a una etapa de preprocesamiento con el objetivo de mejorar su calidad y reducir la influencia de componentes no deseados que pudieran afectar el desempeño de los modelos de inteligencia artificial. Debido a que las señales EMG son susceptibles a diversas fuentes de ruido, resulta necesario aplicar técnicas de acondicionamiento que permitan conservar únicamente la información relevante asociada a la actividad muscular.

Inicialmente, las señales fueron procesadas mediante un filtro digital pasa banda con frecuencias de corte de 20 Hz y 450 Hz. Este rango fue seleccionado debido a que concentra la mayor parte de la energía útil presente en las señales electromiográficas superficiales. La aplicación de este filtro permitió atenuar componentes de baja frecuencia asociados al movimiento de los electrodos, desplazamientos de la línea base y artefactos producidos por el movimiento corporal, así como reducir componentes de alta frecuencia relacionadas con ruido electrónico y otras interferencias externas.

Posteriormente, se implementó un filtro Notch centrado en 60 Hz con la finalidad de minimizar la interferencia generada por la red eléctrica. Este tipo de ruido suele estar presente durante la adquisición de señales biomédicas debido a la proximidad de equipos

electrónicos y sistemas de alimentación eléctrica. La eliminación de esta componente permitió mejorar la relación señal-ruido y obtener registros más representativos de la actividad muscular real.

Una vez filtradas las señales, se realizó un proceso de normalización para mantener una escala uniforme entre todas las muestras registradas. Esta etapa es especialmente importante debido a que la amplitud de las señales electromiográficas puede variar entre sujetos, sesiones de adquisición e incluso entre diferentes músculos. La normalización permitió reducir dichas variaciones, facilitando la comparación entre registros y mejorando la estabilidad numérica durante el entrenamiento de los algoritmos de clasificación.

Finalmente, las señales preprocesadas fueron inspeccionadas para verificar la correcta eliminación de ruido y asegurar que la información muscular de interés se conservara adecuadamente. El resultado de esta etapa fue un conjunto de señales acondicionadas y listas para los procesos de segmentación, extracción de características y entrenamiento de los modelos de inteligencia artificial desarrollados en esta investigación.

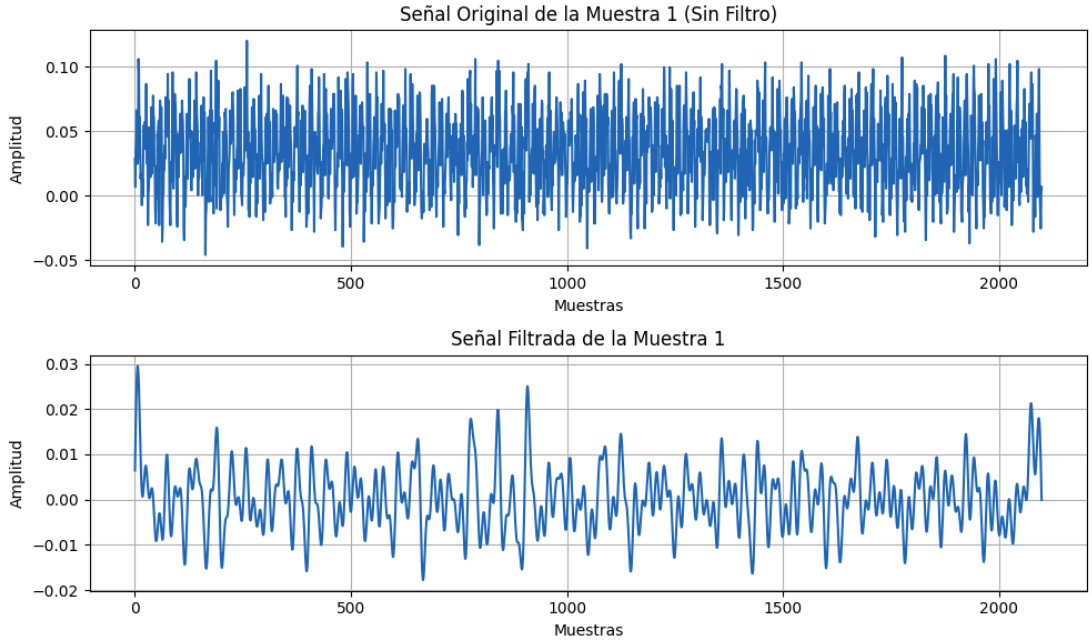


Figura 6.7: Comparativa entre señales sin filtrar y señales filtradas.

6.1.6.2. Depuración de muestras Se eliminaron las muestras que no contenían el número esperado de datos por canal, garantizando uniformidad dimensional en toda la base de datos.

Este procedimiento permitió reducir errores durante el entrenamiento y validación de los modelos de inteligencia artificial.

6.1.6.3. Extracción de características A partir de las señales procesadas se calcularon diferentes características estadísticas utilizadas como variables de entrada para los modelos de clasificación.

Las características extraídas fueron: media, desviación estándar, valor RMS, valor máximo, valor mínimo y varianza

Estas características permitieron construir una matriz de atributos compatible con los algoritmos de aprendizaje supervisado.

6.2. Entrenamiento y Comparativa de Modelos de Inteligencia Artificial

6.2.1. Modelos evaluados

Se evaluaron distintos modelos de aprendizaje supervisado utilizando PyCaret y bibliotecas complementarias de Python.

Los algoritmos considerados fueron Naïve Bayes, QDA, SVM, KNN, Random Forest y Extra Trees.

La selección de estos modelos se realizó con base en antecedentes reportados en investigaciones relacionadas con clasificación de señales electromiográficas.

6.2.2. Métricas de evaluación

La evaluación de los modelos se realizó mediante validación cruzada y conjuntos independientes de prueba. Las métricas utilizadas fueron Accuracy, Recall, Precision, F1-score.

El criterio principal de selección fue el F1-score debido a su capacidad para balancear precisión y sensibilidad.

6.2.3. Clasificación del tipo de movimiento

Se desarrolló un sistema de clasificación multiclase encargado de identificar tres movimientos: Flexión plantar, flexión dorsal y posición neutra.

Se entrenaron distintos modelos de clasificación utilizando las características estadísticas extraídas de las señales electromiográficas.

El modelo Naïve Bayes presentó el mejor desempeño durante las pruebas de validación y prueba independiente, alcanzando los valores más altos en las métricas evaluadas.

6.2.4. Detección de asimetría muscular

Se implementó un segundo modelo de clasificación orientado a detectar diferencias musculares entre extremidades inferiores.

Las señales fueron etiquetadas según correspondieran a una pierna funcional o a una pierna con alteración muscular.

Para este proceso se utilizaron características estadísticas como RMS, media y desviación estándar.

El modelo QDA presentó el mejor desempeño para esta tarea, alcanzando una exactitud del 93.33 %.

6.2.5. Selección y justificación de modelos

La selección final de modelos se realizó considerando tanto el desempeño estadístico como la estabilidad obtenida durante las pruebas experimentales.

El modelo QDA fue seleccionado para la detección de anomalías musculares debido a su capacidad para modelar clases con diferentes covarianzas, condición observada en las señales electromiográficas adquiridas.

Por otro lado, Naïve Bayes fue seleccionado para la clasificación del movimiento debido a su alta precisión y estabilidad con conjuntos de datos moderados y características estadísticas normalizadas.

6.3. Sistema de Control Difuso

6.3.1. Variables del sistema

El sistema de control difuso fue implementado mediante la biblioteca `scikit-fuzzy`.

- Entrada 1: Intensidad Representa el nivel de anomalía detectado por el sistema de clasificación.
- Entrada 2: Umbral de dolor Corresponde al nivel de tolerancia definido por el usuario.
- Salida: Voltaje de estimulación Representa el nivel de estimulación eléctrica aplicado al músculo.

6.3.2. Funciones de membresía

Se utilizaron funciones de membresía triangulares para representar las etiquetas lingüísticas de entrada y salida.

6.3.2.1. Entrada 1: Intensidad

- Débil: $\mu(x) = \text{trimf}(x; -5, -5, 0)$
- Moderada: $\mu(x) = \text{trimf}(x; -1, 0, 1)$
- Fuerte: $\mu(x) = \text{trimf}(x; 0, 5, 5)$

6.3.2.2. Entrada 2: Umbral de dolor

- Bajo: $\mu(x) = \text{trimf}(x; 1, 1, 4)$
- Medio: $\mu(x) = \text{trimf}(x; 3, 5, 7)$
- Alto: $\mu(x) = \text{trimf}(x; 6, 10, 10)$

6.3.2.3. Salida: Voltaje

- Bajo: $\mu(x) = \text{trimf}(x; 0, 0, 5)$
- Medio: $\mu(x) = \text{trimf}(x; 2, 5, 8)$
- Alto: $\mu(x) = \text{trimf}(x; 5, 10, 10)$

6.3.3. Reglas difusas

El sistema difuso fue implementado utilizando inferencia tipo Mamdani. Las reglas establecidas relacionan la intensidad de la anomalía detectada y el umbral de dolor reportado por el usuario con el nivel de estimulación eléctrica requerido.

a. Si la intensidad es débil y el umbral es bajo, entonces el voltaje es bajo.

b. Si la intensidad es débil y el umbral es medio, entonces el voltaje es medio.

c. Si la intensidad es débil y el umbral es alto, entonces el voltaje es alto.

d. Si la intensidad es moderada y el umbral es bajo, entonces el voltaje es bajo.

e. Si la intensidad es moderada y el umbral es medio, entonces el voltaje es medio.

f. Si la intensidad es moderada y el umbral es alto, entonces el voltaje es medio.

g. Si la intensidad es fuerte y el umbral es bajo, entonces el voltaje es bajo.

h. Si la intensidad es fuerte y el umbral es medio, entonces el voltaje es bajo.

i. Si la intensidad es fuerte y el umbral es alto, entonces el voltaje es bajo.

6.3.4. Generación de estimulación eléctrica

Con base en las reglas difusas y los resultados obtenidos por los modelos de clasificación, el sistema calculó el nivel de voltaje necesario para la activación muscular.

La estimulación generada tuvo como objetivo asistir el movimiento funcional del usuario durante diferentes fases de la marcha.

7. Resultados y discusión

7.1. Base de Datos

En esta sección se presentan los resultados obtenidos durante la conformación, organización y procesamiento de la base de datos. Se consideran las etapas de adquisición de las señales mioeléctricas, conversión y organización de los registros, procesamiento de las señales, depuración de muestras y extracción de características.

7.2. Población de estudio

La base de datos utilizada en este trabajo estuvo conformada por los registros obtenidos durante las pruebas de adquisición de señales mioeléctricas. Los registros fueron organizados de acuerdo con las características establecidas durante la etapa de adquisición y con las etiquetas correspondientes a cada condición evaluada.

7.3. Preparación del participante

Durante la adquisición se mantuvieron las condiciones de preparación establecidas en la metodología con la finalidad de obtener señales mioeléctricas adecuadas para su posterior procesamiento.

Los registros obtenidos fueron revisados antes de incorporarse a las etapas posteriores del procesamiento, con la finalidad de identificar aquellos que no cumplieran con las condiciones establecidas para el análisis.

7.4. Colocación de sensores

La adquisición de las señales mioeléctricas se realizó mediante electrodos superficiales colocados sobre los músculos considerados en el estudio. Los registros correspondientes a cada músculo fueron organizados de manera independiente para permitir su posterior procesamiento y análisis.

7.4.1. Músculo tibial anterior

Los registros correspondientes al músculo tibial anterior fueron organizados de acuerdo con la pierna y el movimiento realizado durante cada prueba.

7.4.2. Músculo gastrocnemio

De manera equivalente, los registros correspondientes al músculo gastrocnemio fueron organizados de acuerdo con la pierna y el movimiento registrado.

7.5. Adquisición de señales

Las señales mioeléctricas obtenidas durante las pruebas fueron almacenadas inicialmente en los archivos correspondientes al sistema de adquisición. Posteriormente, los registros fueron revisados y organizados para facilitar su procesamiento.

En esta etapa se debe presentar la información correspondiente a los registros obtenidos, incluyendo el número de registros, duración de cada prueba, músculo, pierna y movimiento realizado.

Cuadro 7.1: Características de los registros utilizados en el estudio.

Registro	**Pierna**	**Músculo**	**Movimiento**	**Duración**	**Muestras**
Flexión plantar	*Izquierda/Derecha*	*Tibial y Gastronecmio*	*Punta abajo*	*5s*	2100
Flexion dorsal	*Izquierda/Derecha*	*Tibial y Gastronecmio*	*Punta arriba*	*5s*	2100
Neutra	*Izquierda/Derecha*	*Tibial y Gastronecmio*	*Reposo*	*5s*	2100

7.6. Conversión y organización de la base de datos

Los registros obtenidos fueron convertidos y organizados para generar una estructura adecuada para el procesamiento computacional. Los datos fueron clasificados de acuerdo con el canal, registro y etiqueta correspondiente.

Esta organización permitió establecer una estructura uniforme para las etapas posteriores de filtrado, depuración y extracción de características.

7.7. Procesamiento de señales

El procesamiento de las señales se realizó antes de la extracción de características. Esta etapa permitió obtener registros con una estructura adecuada para su utilización en los modelos de inteligencia artificial.

7.7.1. Filtrado y normalización

Las señales fueron sometidas al procesamiento establecido en la metodología. Posteriormente, se realizó la normalización de los registros con la finalidad de obtener señales comparables entre las diferentes observaciones.

7.7.2. Depuración de muestras

Después del filtrado y la normalización, los registros fueron revisados para verificar que cumplieran con la longitud establecida para el análisis.

Los registros utilizados en el análisis fueron aquellos que cumplieron con la condición establecida de 2100 muestras por registro. Las muestras iniciales contenían la información de 4 canales, debido a que solo se ocupaban 2 canales se depuró la información de 2 canales.

Cuadro 7.2: Resultado de la depuración de la base de datos.

Descripción	**Cantidad**
Registros iniciales	*[403]*
Registros descartados	*[9]*
Registros utilizados	*[200]*
Muestras por registro	2100

7.7.3. Extracción de características

A partir de los registros depurados se realizó la extracción de características estadísticas de las señales mioeléctricas.

Las características utilizadas fueron la media, desviación estándar, valor mínimo, valor máximo y raíz cuadrática media (RMS).

Cuadro 7.3: Características extraídas de las señales mioeléctricas.

Característica	**Descripción**
Media	Valor promedio de la señal
Desviación estándar	Dispersión de los valores
Mínimo	Valor mínimo de la señal
Máximo	Valor máximo de la señal
RMS	Raíz cuadrática media

Las características obtenidas fueron utilizadas como variables de entrada para las tareas de clasificación consideradas en el estudio. Por lo tanto, la extracción de características constituye una etapa común para la detección de asimetría muscular y para la clasificación del tipo de movimiento.

7.8. Entrenamiento y Comparativa de Modelos de Inteligencia Artificial

A partir de la matriz de características obtenida durante el procesamiento de las señales, se realizó el entrenamiento y comparación de diferentes modelos de inteligencia artificial.

El análisis se dividió en dos tareas: la clasificación del tipo de movimiento y la detección de asimetría muscular.

7.8.1. Modelos evaluados

Se evaluaron diferentes modelos de clasificación mediante la herramienta utilizada para la comparación de modelos. El desempeño de los modelos fue analizado mediante las métricas establecidas en la metodología.

7.8.2. Métricas de evaluación

Para la comparación de los modelos se consideraron las métricas de Accuracy, AUC, Recall, Precision y F1-score.

Estas métricas permitieron analizar el desempeño de cada modelo desde diferentes perspectivas y seleccionar los modelos utilizados en las etapas posteriores del sistema.

7.9. Clasificación del tipo de movimiento

La clasificación del tipo de movimiento consideró tres clases: dorsal, nulo y plantar.

Los resultados de la comparación de modelos se presentan en la Tabla 7.4.

Cuadro 7.4: Comparación de modelos para la clasificación del tipo de movimiento.

Modelo	**Accuracy**	**AUC**	**Recall**	**Precision**	**F1**
Naive Bayes	0.9750	0.9812	0.9750	0.9822	0.9738
Extra Trees	0.9750	0.9979	0.9750	0.9800	0.9746
Random Forest	0.9256	0.9849	0.9256	0.9449	0.9254
Gradient Boosting	0.9013	0.0000	0.9013	0.9267	0.8994
SVM	0.8763	0.9603	0.8763	0.8964	0.8684

El modelo Naive Bayes obtuvo una exactitud de 97.50 98.12 F1-score de 97.38

El modelo Extra Trees presentó una exactitud de 97.50 99.79 el conjunto de métricas establecido, Naive Bayes fue utilizado para la clasificación del tipo de movimiento.

7.9.1. Resultados de validación

Durante la etapa de validación, el modelo Naive Bayes presentó los resultados registrados para las tres clases de movimiento.

7.9.2. Resultados de prueba

En el conjunto de prueba, el modelo Naive Bayes obtuvo una exactitud de 98

Cuadro 7.5: Resultados de validación del modelo Naive Bayes.

Clase	Precision	Recall	F1-score	Soporte
Dorsal	1.00	1.00	1.00	19
Nulo	1.00	1.00	1.00	19
Plantar	1.00	1.00	1.00	20
Accuracy		1.00		58

Cuadro 7.6: Resultados de prueba del modelo Naive Bayes.

Clase	Precision	Recall	F1-score	Soporte
Dorsal	0.95	1.00	0.98	20
Nulo	1.00	1.00	1.00	18
Plantar	1.00	0.95	0.97	20
Accuracy		0.98		58

7.10. Detección de asimetría muscular

Para la detección de asimetría muscular se evaluaron diferentes modelos de clasificación utilizando las características extraídas de las señales mioeléctricas.

Las clases consideradas fueron *Sana* y *Débil*.

Cuadro 7.7: Comparación de modelos para la detección de asimetría muscular.

Modelo	Accuracy	AUC	Recall	Precision	F1
QDA	0.9333	0.9667	0.9667	0.9350	0.9407
KNN	0.9000	0.9278	1.0000	0.8600	0.9179
Naive Bayes	0.8833	0.9222	0.9333	0.8767	0.8931
Extra Trees	0.8667	0.9389	0.9333	0.8517	0.8788
Decision Tree	0.8667	0.8667	0.9000	0.8683	0.8740
Random Forest	0.8667	0.9444	0.9000	0.8767	0.8731
LightGBM	0.8500	0.8833	0.9000	0.8517	0.8588
SVM	0.7500	0.8000	0.7333	0.6850	0.6979

El modelo QDA obtuvo una exactitud de 93.33 un recall de 96.67 94.07

La matriz de confusión obtenida para QDA se muestra en la Tabla 7.8.

La matriz de confusión muestra 12 clasificaciones correctas para la clase *Sana* y 12 para la clase *Débil*. Asimismo, se observó una clasificación incorrecta para cada una de las clases.

Cuadro 7.8: Matriz de confusión del modelo QDA.

	Predicción	
Clase real	**Sana**	**Débil**
Sana	12	1
Débil	1	12

7.11. Selección y justificación de modelos

Con base en la comparación realizada, se seleccionaron dos modelos para las etapas posteriores del sistema.

Para la detección de asimetría muscular se seleccionó QDA, mientras que para la clasificación del tipo de movimiento se utilizó Naive Bayes.

Los dos modelos realizan tareas independientes dentro del sistema: QDA permite identificar la condición asociada con la asimetría muscular y Naive Bayes permite determinar el tipo de movimiento presente en la señal.

7.12. Sistema de Control Difuso

Una vez obtenidas las salidas de los modelos de inteligencia artificial, se desarrolló el sistema de control difuso para generar una respuesta de estimulación eléctrica mediante simulación.

7.12.1. Variables del sistema

El sistema de control difuso utiliza como variables de entrada la intensidad de la anomalía y el umbral de dolor. La salida corresponde al voltaje de estimulación eléctrica.

La intensidad de la anomalía se consideró dentro del intervalo $[-5, 5]$, mientras que el voltaje de salida se estableció dentro del intervalo $[0, 5]$ V.

7.12.2. Funciones de membresía

Las funciones de membresía permitieron representar las variables de entrada y salida mediante conjuntos difusos.

7.12.3. Entrada 1: Intensidad

La intensidad de la anomalía constituye la primera entrada del controlador. El valor de esta variable fue utilizado para determinar el grado de pertenencia a los conjuntos difusos definidos.

7.12.4. Entrada 2: Umbral de dolor

El umbral de dolor constituye la segunda entrada del controlador y permite incorporar esta condición en el proceso de inferencia difusa.

7.12.5. Salida: Voltaje

La salida del controlador corresponde al voltaje de estimulación eléctrica simulado, con un intervalo de 0 a 5 V.

7.13. Reglas difusas

Las reglas difusas relacionan las condiciones de las entradas con la respuesta correspondiente del controlador.

La inferencia se realizó mediante un sistema difuso de tipo Mamdani. De manera general, las reglas pueden representarse mediante:

$$\text{SI } X_1 \text{ es } A \text{ Y } X_2 \text{ es } B \text{ ENTONCES } Y \text{ es } C \tag{7.1}$$

donde X_1 corresponde a la intensidad de la anomalía, X_2 al umbral de dolor y Y al voltaje de salida.

Cuadro 7.9: Reglas del sistema de control difuso.

Intensidad	**Umbral de dolor**	**Voltaje**
[Media]	*[Baja]*	*[2.31]*
[Baja]	*[Baja]*	*[0]*
[Baja]	*[Baja]*	*[3.74]*

7.14. Generación de estimulación eléctrica

La respuesta del controlador fue evaluada mediante una simulación dinámica en la que se consideraron diferentes fases del ciclo de marcha.

Las fases consideradas fueron apoyo inicial, apoyo medio, despegue y balanceo. Para cada fase se estableció una condición de movimiento y una intensidad de anomalía, a partir de las cuales se obtuvo la respuesta del controlador.

7.15. Evaluación mediante RMSE

Para evaluar el comportamiento del controlador se calculó la raíz del error cuadrático medio (RMSE) entre los valores de referencia y los valores generados durante la simulación.

El RMSE se calculó mediante:

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \tag{7.2}$$

donde y_i corresponde al valor de referencia y $\hat{y}_i$ al valor generado por el controlador.

Los resultados obtenidos fueron:

Cuadro 7.10: Resultados de la evaluación del controlador mediante RMSE.

Músculo	**RMSE (V)**	**Error relativo**
Tibial anterior	0.80	15.96 %
Pantorrilla	0.23	4.58 %

El RMSE obtenido para el tibial anterior fue de 0.80 V, mientras que para la pantorrilla fue de 0.23 V. Estos valores corresponden a la comparación entre la respuesta simulada y los valores de referencia establecidos para la evaluación del controlador.

Es importante señalar que estos resultados corresponden a una evaluación mediante simulación y no a una aplicación física de estimulación eléctrica.

7.16. Visualización de la estimulación por fase

A continuación se describen las respuestas generadas por el sistema de control difuso para cada una de las fases del ciclo de marcha, considerando entradas aleatorias en el rango [-5, 5].

Fase 1 – Apoyo inicial: Durante esta fase se identifica un movimiento de dorsiflexión con presencia de anomalía. El sistema difuso recibe una intensidad aleatoria positiva y activa el músculo tibial anterior con un voltaje proporcional al grado de la anomalía (ver figura 7.1). La pantorrilla permanece inactiva, como corresponde fisio-lógicamente.

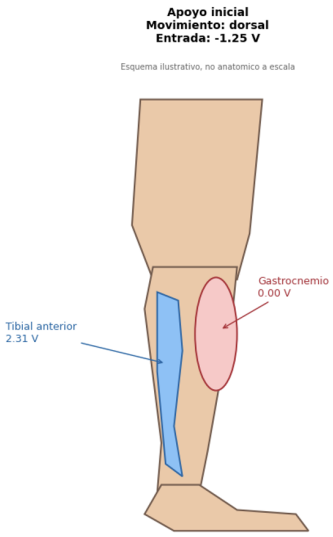


Figura 7.1: Simulación de estimulación en apoyo inicial.

Fase 2 – Apoyo medio: Esta fase no requiere activación muscular específica, ya que el pie está en contacto estable con el suelo. El sistema reconoce un movimiento nulo sin anomalía y ambos músculos permanecen sin estimulación, tal como se espera de un comportamiento fisiológico normal (ver fig. 7.2).

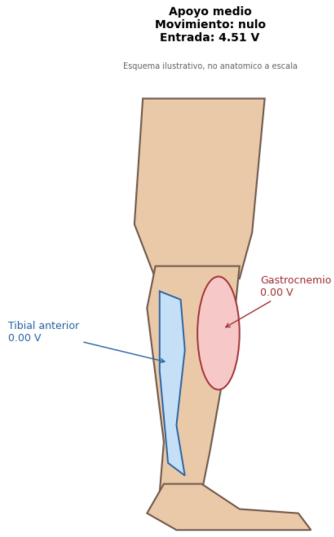


Figura 7.2: Simulación en fase de apoyo medio. No se requiere estimulación.

Fase 3 – Despegue: Se presenta una fase de propulsión plantar con presencia de anomalías. El sistema aplica una estimulación significativa en el músculo de la pantorrilla,

que es el principal responsable del impulso necesario para separar el pie del suelo (ver fig. 7.3. El voltaje generado es proporcional a la intensidad aleatoria asignada a esta fase.

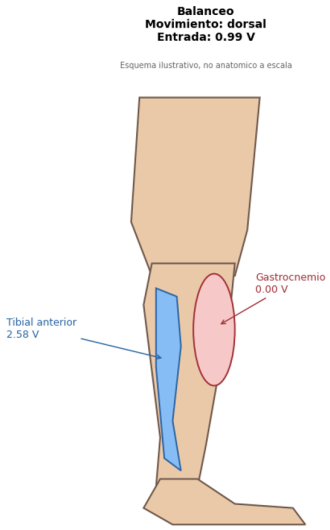


Figura 7.3: Simulación fase de despegue.

Fase 4 – Balanceo: En esta etapa, el sistema identifica nuevamente un movimiento dorsal con anomalía. Para evitar el arrastre del pie el sistema activa el tibial anterior, facilitando el levantamiento del pie durante la oscilación. El nivel de voltaje generado responde a la entrada aleatoria de esta fase.

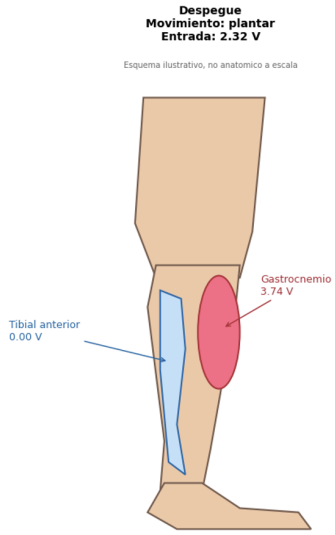


Figura 7.4: Simulación fase de balanceo.

8. Conclusiones

En este trabajo se logró integrar la detección de anomalías en señales mioeléctricas, la clasificación de movimientos durante la marcha y el control de estimulación mediante lógica difusa dentro de un sistema funcional. A diferencia de la mayoría de estudios previos centrados en miembros superiores, esta investigación se enfocó en las extremidades inferiores, proponiendo una solución novedosa para el apoyo neuromuscular durante el ciclo de la marcha.

El análisis de distintos modelos de clasificación evidenció que el QDA ofreció un mejor desempeño en la detección de anomalías, mientras que el modelo de NB fue más adecuado para la clasificación de tipos de movimiento. Esto demuestra que no existe un modelo único óptimo, sino que la elección depende del tipo de señal y del objetivo específico del análisis.

Las señales electromiográficas fueron preprocesadas con técnicas básicas de limpieza, lo cual permitió mejorar la precisión del sistema. Sin embargo, se identificó la necesidad de implementar técnicas más avanzadas, como la transformación wavelet, para mejorar la caracterización de las señales en futuros trabajos.

Uno de los hallazgos más relevantes fue que la estructura de los datos influye directamente en el rendimiento de los modelos. El uso de información en forma de matriz, en lugar de una sola dimensión por canal, permitió mejorar la interpretación de las señales y optimizar el proceso de clasificación. Esto sugiere que el sistema puede ser escalado a múltiples sensores y músculos, generando una base de datos más robusta y un sistema más preciso.

Cabe mencionar que la base de datos desarrollada se enfocó únicamente en mujeres, debido a la naturaleza de la implementación experimental. Queda pendiente la validación con sujetos masculinos para ampliar la generalización del sistema.

Finalmente, esta investigación confirma que los sistemas inteligentes híbridos pueden ser una alternativa viable y adaptable en el diseño de tecnologías para la asistencia neuromuscular, abriendo camino a futuras aplicaciones en prótesis activas, sistemas inalámbricos de estimulación y plataformas de rehabilitación domiciliaria.

8.1. Discusión general de los resultados

Los resultados obtenidos muestran que el procesamiento de las señales mioeléctricas permitió generar una matriz de características para su utilización en las tareas de clasificación.

La comparación de modelos permitió seleccionar QDA para la detección de asimetría muscular y Naive Bayes para la clasificación del tipo de movimiento.

Posteriormente, las salidas de estas etapas fueron consideradas dentro del sistema de control difuso tipo Mamdani. El controlador generó una respuesta de voltaje mediante simulación para las condiciones establecidas.

Finalmente, la evaluación mediante RMSE permitió cuantificar la diferencia entre los valores de referencia y los valores obtenidos durante la simulación. El RMSE obtenido

fue de 0.80 V para el tibial anterior y 0.23 V para la pantorrilla.

Los resultados obtenidos corresponden al alcance establecido para el estudio, por lo que el funcionamiento del sistema fue evaluado mediante simulación y no mediante la aplicación física de estimulación eléctrica sobre un participante.

Referencias bibliográficas

[1] R. Merletti and D. Farina, *Surface electromyography: physiology, engineering, and applications*. John Wiley & Sons, 2016.

[2] C. J. De Luca, "The use of surface electromyography in biomechanics," *Journal of applied biomechanics*, vol. 13, no. 2, pp. 135–163, 1997.

[3] World Health Organization, "Neurological disorders: Public health challenges," 2021, consultado en junio de 2025. [Online]. Available: https://www.who.int/publications/i/item/9789240068476

[4] J. e. a. Smith, "Peripheral neuropathy and diabetes: Epidemiological links and impacts," *Journal of Neurological Sciences*, vol. 420, pp. 117–125, 2022.

[5] A. Rodríguez and M. Pérez, "Artificial neural network-based rehabilitation system for hand movement," *IEEE Trans. on Neural Systems and Rehabilitation Engineering*, 2021.

[6] F. Ayachi and M. Ben Khelifa, "Support vector machines for prosthetic control," *Biomedical Signal Processing and Control*, 2022.

[7] I. Dimitrov and T. Georgiev, "Knn applied to emg classification in real-time prosthetic devices," *Sensors*, 2021.

[8] T. J. Ross, *Fuzzy Logic with Engineering Applications*, 4th ed. John Wiley & Sons, 2016.

[9] L. Carvalho and J. Gonçalves, "Real-time fes feedback system using narx neural networks and fuzzy controllers," *IEEE Access*, vol. 8, pp. 20 795–20 805, 2020.

[10] A. Phinyomark, P. Phukpattaranont, and C. Limsakul, "Feature reduction and selection for emg signal classification," *Expert Systems with Applications*, vol. 39, no. 8, pp. 7420–7431, 2012. [Online]. Available: https://www.sciencedirect.com/science/article/pii/S0957417412001200

[11] M. Z.-E.-A. Amrani, A. Daoudi, N. Achour, and M. Tair, "Artificial neural networks based myoelectric control system for automatic assistance in hand rehabilitation," in *2017 26th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*. IEEE, 2017, pp. 968–973.

[12] A. Nasr, B. Laschowski, and J. McPhee, "Myoelectric control of robotic leg prostheses and exoskeletons: A review," in *International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*, vol. 85444. American Society of Mechanical Engineers, 2021, p. V08AT08A043.

[13] D. Simonetti, B. Koopman, and M. Sartori, "Automated estimation of ankle muscle emg envelopes and resulting plantar-dorsi flexion torque from 64 garment-embedded electrodes uniformly distributed around the human leg," *Journal of Electromyography and Kinesiology*, vol. 67, p. 102701, 2022.

[14] F. S. Ayachi, S. Boudaoud, and C. Marque, "Evaluation of muscle force classification using shape analysis of the semg probability density function: a simulation study," *Medical & biological engineering & computing*, vol. 52, no. 8, pp. 673–684, 2014.

[15] N. Jose, R. Raj, P. Adithya, and K. Sivanadan, "Classification of forearm movements from semg time domain features using machine learning algorithms," in *TENCON 2017-2017 IEEE region 10 conference*. IEEE, 2017, pp. 1624–1628.

[16] G. V. Dimitrov, T. I. Arabadzhiev, K. N. Mileva, J. L. Bowtell, N. Crichton, and N. A. Dimitrova, "Muscle fatigue during dynamic contractions assessed by new spectral indices," *Medicine and science in sports and exercise*, vol. 38, no. 11, p. 1971, 2006.

[17] P. Geethanjali, "Myoelectric control of prosthetic hands: state-of-the-art review," *Medical Devices: Evidence and Research*, pp. 247–255, 2016.

[18] A. Mathew and P. Rajalakshmy, "Surface electromyogram based techniques for upper and lower extremity rehabilitation therapy-a comprehensive review," in *2021 3rd International Conference on Signal Processing and Communication (ICPSC)*. IEEE, 2021, pp. 26–30.

[19] S. Carvalho, A. Correia, J. Figueiredo, J. M. Martins, and C. P. Santos, "Functional electrical stimulation system for drop foot correction using a dynamic narx neural network," *Machines*, vol. 9, no. 11, p. 253, 2021.

[20] A. Phinyomark, R. N. Khushaba, and E. Scheme, "Feature extraction and selection for myoelectric control based on wearable emg sensors," *Sensors*, vol. 18, no. 5, p. 1615, 2018.

[21] R. Merletti and P. A. Parker, *Electromyography: Physiology, Engineering, and Non-Invasive Applications*. Hoboken, New Jersey, USA: John Wiley & Sons, 2004.

[22] P. Konrad, *The ABC of EMG: A Practical Introduction to Kinesiological Electromyography*. Scottsdale, Arizona, USA: Noraxon Inc., 2005.

[23] C. J. De Luca, "The use of surface electromyography in biomechanics," *Journal of Applied Biomechanics*, vol. 13, pp. 135–163, 1997.

[24] A. Phinyomark, P. Phukpattaranont, and C. Limsakul, "Feature reduction and selection for emg signal classification," *Expert Systems with Applications*, vol. 39, no. 8, pp. 7420–7431, 2012.

[25] H. J. Hermens, B. Freriks, C. Disselhorst-Klug, and G. Rau, "Development of recommendations for semg sensors and sensor placement procedures," *Journal of Electromyography and Kinesiology*, vol. 10, no. 5, pp. 361–374, 2000.

[26] D. Stegeman and H. Hermens, "Standards for surface electromyography: The european project seniam," *SENIAM Recommendations*, 2007, disponible en: https://www.researchgate.net/publication/228486725.

[27] I. Medical, "¿qué es y qué enfermedades se detectan con una electromiografía?" 2025, accedido el 2 de junio de 2025. [Online]. Available: https://www.invoxmedical.com/blog/que-es-y-que-enfermedades-se-detectan-con-una-electromiografia

[28] S. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*, 3rd ed. Pearson Education, 2010.

[29] Minitab Support, "¿qué es análisis discriminante cuadrático?" https://support.minitab.com/es-mx/minitab/help-and-how-to/statistical-modeling/multivariate/supporting-topics/discriminant-analysis/what-is-quadratic-discriminant-analysis/, 2022, consultado en junio de 2025.

[30] IBM Documentation, "Análisis discriminante en ibm spss statistics," https://www.ibm.com/docs/es/spss-statistics/beta?topic=features-discriminant-analysis, 2023, consultado en junio de 2025.

[31] IBM Think Blog, "¿qué es naïve bayes?" https://www.ibm.com/es-es/think/topics/naive-bayes, 2023, consultado en junio de 2025.

[32] K. P. Murphy, *Machine Learning: A Probabilistic Perspective*. MIT Press, 2012.

[33] E. Kavlakoglu. ¿Qué es el algoritmo de k vecinos más cercanos? — IBM — ibm.com. https://www.ibm.com/mx-es/think/topics/knn. [Accessed 01-06-2026].

[34] C. Cortes and V. Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273–297, 1995.

[35] IBM, "¿qué son las máquinas de vector de soporte (SVM)?" https://www.ibm.com/mx-es/think/topics/support-vector-machine, 2026, accedido: 10 de junio de 2026.

[36] T. J. Ross, *Fuzzy Logic with Engineering Applications*, 3rd ed. Chichester, United Kingdom: John Wiley & Sons, 2010.

[37] F. e. a. Ayachi, "Control de prótesis mediante svm con señales emg," *Medical Engineering and Physics*, vol. 41, pp. 70–78, 2019.

[38] L. A. Zadeh, "Fuzzy sets," *Information and Control*, vol. 8, no. 3, pp. 338–353, 1965.

[39] T. Chai and R. R. Draxler, "Root mean square error (rmse) or mean absolute error (mae)?–arguments against avoiding rmse in the literature," *Geoscientific Model Development*, vol. 7, no. 3, pp. 1247–1250, 2014.

[40] J. Perry and J. M. Burnfield, *Gait Analysis: Normal and Pathological Function*, 2nd ed. Thorofare, New Jersey, USA: SLACK Incorporated, 2010.

9. Anexos

UNIVERSIDAD AUTÓNOMA DE QUERÉTARO

FACULTAD DE INGENIERÍA

CARTA DE CONSENTIMIENTO INFORMADO

Querétaro, Querétaro, a ___ de _____del año 20___

Antes de expresar y en su caso aceptar participar, por favor lea este consentimiento cuidadosamente. Haga todas las preguntas y dudas que se produzcan, para asegurarse de que entienda los objetivos, procedimientos y resultados del estudio, incluyendo los posibles riesgos y los beneficios.

Propósito Principal del estudio: Desarrollar un sistema de control difuso a traves de la clasificación de las señales mioelectricas de miembros inferiores utilizando técnicas de machine learning. Las señales obtenidas serán parte del entrenamiento de una maquina de soporte de vectores.

Participantes: La participación es completamente voluntaria. Puede permanecer o abandonar la intervención en cualquier momento. Los datos e información que proporcione y que se obtendrán de las mediciones es parte de su propiedad, por lo que en caso de requerir la información obtenida, podrá ser compartida, a través de la firma del consentimiento informado autoriza a utilizarlos para lograr un beneficio para esta investigación.

Tiempo requerido: Aproximadamente 40 minutos por persona para completar todas las evaluaciones, durante la jornada programada para el día _____ del mes _____ en un horario de las _____ hasta las _____.

Beneficios: Esta investigación no busca obtener beneficio económico alguno, ni para el investigador, ni para los colaboradores del estudio. Si decide participar, tendrá derecho a solicitar toda la información sobre los resultados obtenidos y los análisis que se deriven de la información registrada durante todo el proceso.

Derecho a retirarse del estudio de investigación: Puede retirarse del estudio en cualquier momento. Sin embargo, los datos obtenidos hasta ese momento seguirán formando parte del estudio a menos que solicite expresamente que su identificación y su información sea borrada de la base de datos. Podrá retirarse sin penalización o represalia alguna.

Procedimiento: Las pruebas del sistema se llevarán a cabo bajo la supervisión directa y acompañamiento del ingeniero Carlos Alberto Bacilio Díaz, en los horarios que se le asignaron de acuerdo con la agenda de actividades del día ____ y año _____.

El procedimiento para la obtención de datos es colocar electrodos en la piel previamente limpiada con alcohol, serán colocados en los musculos tibial anterior y un par en un músculo gastronecmio, otro electrodo se colocará en la terminación del hueso fibula cerca del pie. El participante deberá de caminar para poder obtener la información de los músculos. Una vez terminada la obtención de datos,

podrá retirarse los electrodos de la piel. La obtención de datos será en una sesión, durante la sesión se pedirá repetir los patrones de caminar dos o tres veces.

Todos los procedimientos, equipos y materiales utilizados para la evaluación son de tipo no invasiva lo que significa que en ningún caso tendrá que ingerir, recibir o sentir ningún dolor. Las pruebas del sistema tendrán la modalidad de intervenciones breves que significa que cada intervención o procedimiento en el que participará si está de acuerdo no tendrá una duración mayor de 40 minutos en total por persona.

Investigadores principales durante la aplicación del protocolo:

Ing. Carlos Alberto Bacilio Díaz, Facultad de ingeniería UAQ

Dr. Andras Takacs, Facultad de ingeniería UAQ

Dr. Saúl Tovar Arriaga, Facultad de ingeniería UAQ

Dr. Juvenal Rodríguez Reséndiz, Facultad de ingeniería UAQ

Yo, _____ he leído el procedimiento descrito en el presente documento. El equipo de investigadores responsables me ha explicado el estudio y han contestado mis preguntas. Voluntariamente doy mi consentimiento para participar en el proyecto denominado "Generación de señales mioeléctricas para rehabilitación de miembros inferiores mediante lógica difusa y machine learning".

_____

Firma del participante

Preguntas o dudas sobre los derechos como participante en este proyecto, pueden ser dirigidas a: Carlos Alberto Bacilio Díaz (cbacilio03@alumnos.uaq.mx).

UNIVERSIDAD AUTÓNOMA DE QUERÉTARO

FACULTAD DE INGENIERÍA

CARTA DE CONFIDENCIALIDAD DE DATOS

Querétaro, Querétaro, a ___ de _____del año 20___

A QUIEN CORRESPONDA

PRESENTE.

Yo, _____ me comprometo a aceptar íntegramente el presente acuerdo de confidencialidad de datos. La información recabada será obtenida bajo el proyecto denominado “Generación de señales mioeléctricas para rehabilitación de miembros inferiores mediante lógica difusa y machine learning”.

Los acuerdos de confidencialidad a los que me comprometo son:

- Resguardar la información obtenida en el presente proyecto de investigación.
- No divulgar ninguna información confidencial.
- La información obtenida sólo será para fines académicos y de investigación.

Así mismo, aceptó los compromisos, exigencias y penalidades que implica la presente carta de confidencialidad de datos.

La información recopilada en el marco del presente proyecto será almacenada de manera segura en una computadora de acceso restringido. Para garantizar la protección de los datos, se implementarán las siguientes medidas de resguardo:

Almacenamiento local seguro: Los datos serán almacenados en una computadora protegida mediante credenciales de acceso, con medidas de seguridad para evitar accesos no autorizados.

Control de acceso: Cualquier persona que requiera acceso a la información deberá solicitar autorización y especificar el uso que se le dará, de la misma forma deberá apegarse a los criterios de confidencialidad.

Protección de la información personal: No se compartirá ninguna información personal de los participantes. Solo se podrán compartir las bases de datos de señales mioeléctricas,

garantizando que los datos sean anonimizados y utilizados exclusivamente para fines de investigación.

Una vez concluido el proyecto, la información será tratada de la siguiente manera:

Conservación de datos anonimizados: Las bases de datos de señales mioeléctricas podrán ser conservadas para futuros estudios, siempre garantizando la confidencialidad y el anonimato de los participantes.

_____

Firma del responsable

Preguntas o dudas sobre los derechos como participante en este proyecto, pueden ser dirigidas a: Ing. Carlos Alberto Bacilio Díaz (cbacilio03@alumnos.uaq.mx).

Facultad de ingeniería, UAQ.

Grupo	Canal	Datos	Etiqueta
Group Name	Sensor 1	[-0.015873991273110732, -0.032644032704411075, -0.012648983305552974, 0.028308617882430553, 0.03024362266296521, 0.0173	Tibial anterior - Pierna izquierda
Group Name #1	Sensor 1	[-0.013938986492576078, 0.005088560516014695, -0.010713978525018321, -0.03296653350116685, -0.08456666098209098, -0.0361	Tibial anterior - Pierna izquierda
Group Name #2	Sensor 1	[0.03701613939348365, 0.010893574857161866, 0.045078659313730896, 0.01863359397975728, -0.014261487289331853, 0.04927116	Tibial anterior - Pierna izquierda
Group Name #3	Sensor 1	[-0.006843968963949001, -0.06876412194105797, -0.048769072542199865, -0.005876466573681682, -0.021679005614714697, -0.024	Tibial anterior - Pierna izquierda
Group Name #4	Sensor 1	[-0.012648983305552974, -0.019744000834180042, -0.015551490476354957, -0.04199655581032857, -0.04070655262330547, -0.053	Tibial anterior - Pierna izquierda
Group Name #5	Sensor 1	[0.02089109955704771, 0.029598621069453657, 0.0025085541419684887, 0.014118582825176418, 0.0044435589225031435, 0.0063	Tibial anterior - Pierna izquierda
Group Name #6	Sensor 1	[0.026696113898651674, -0.013293984899064526, 0.014441083621932194, 0.012183578044641763, 0.022181102744070813, 0.0096	Tibial anterior - Pierna izquierda
Group Name #7	Sensor 1	[0.03153362584998831, 0.015731086808955297, 0.0005735493614338338, 0.04314365453319624, 0.03250112824025564, 0.021536	Tibial anterior - Pierna izquierda
Group Name #8	Sensor 1	[-0.03167653031414375, 0.021213600353803486, 0.006056062906282023, -0.007166469760704786, -0.00684396896394901, -0.0065	Tibial anterior - Pierna izquierda
Group Name #9	Sensor 1	[-0.0429640582005959, 0.00702356529654935, -0.04006155102979392, -0.024904013582272455, 0.011216075654374436, 0.011861(	Tibial anterior - Pierna izquierda
Group Name #10	Sensor 1	[0.006378563703037798, -0.02232400720822625, -0.036191541468724 61, -0.018131496850401163, -0.004263962589902803, -0.036	Tibial anterior - Pierna izquierda
Group Name #11	Sensor 1	[-0.0323215319076553, -0.009746476134750992, 0.02250360354082659, -0.010068976931506768, 0.02701861469540745, 0.012506(	Tibial anterior - Pierna izquierda
Group Name #12	Sensor 1	[-0.023936511192005128, -0.020066501630935818, -0.010068976931506768, -0.017163994460133836, -0.01684149366337806, -0.03	Tibial anterior - Pierna izquierda
Group Name #13	Sensor 1	[-0.08553416337235831, -0.04586656537139788, -0.021679005614714697, -0.012326482508797199, -0.02232400720822625, -0.027(	Tibial anterior - Pierna izquierda
Group Name #14	Sensor 1	[-0.006198967370437458, -0.018131496850401163, 0.014118582825176418, 0.007346066093305126, 0.01637608840246685, 0.0092	Tibial anterior - Pierna izquierda
Group Name #15	Sensor 1	[-0.06489411237998866, -0.07102162751834 84, -0.05070407732273452, -0.0536065844935365, -0.0036189609963912517, 0.005411	Tibial anterior - Pierna izquierda
Group Name #16	Sensor 1	[-0.05296158290002495, -0.020066501630935818, -0.010391477728262544, -0.022324007208226 25, -0.014261487289331853, 0.009	Tibial anterior - Pierna izquierda
Group Name #17	Sensor 1	[0.02250360354082659, 0.012828579638153315, 0.01927859557326883, -0.004263962589902803, 0.008313568483572453, -0.00652	Tibial anterior - Pierna izquierda
Group Name #18	Sensor 1	[-0.0036189609963912517, 0.012506078841397539, 0.008636069280328229, 0.0044435589225031435, -0.021679005614714697, 0.0(	Tibial anterior - Pierna izquierda
Group Name #19	Sensor 1	[0.0025085541419684887, 0.01089357485761866, 0.0015410517517011613, 0.016053587605711073, -0.026516175566051334, -0.00(	Tibial anterior - Pierna izquierda
Group Name #20	Sensor 1	[-0.0029739594028797, 0.05765619038720615, 0.03862864337861538, 0.028953619475942105, -0.006521468167193234, 0.0141185(	Tibial anterior - Pierna izquierda
Group Name #21	Sensor 1	[-0.019421500037424266, -0.013616485695820302, -0.0013614554519100821, -0.015228989679599 18, -0.038771547842770815, -0.0(	Tibial anterior - Pierna derecha
Group Name #22	Sensor 1	[-0.010713978525018321, 0.0025085541419684887, 0.0044435589225031435, 0.015408586012199521, 0.020246097963536158, -0.00(	Tibial anterior - Pierna derecha
Group Name #23	Sensor 1	[0.017988592386245728, -0.017808996053645387, 0.010248573264107108, -0.03070902792387642, -0.011036479321774095, 0.002	Tibial anterior - Pierna derecha
Group Name #24	Sensor 1	[-0.020711503222444737, -0.02748401995631866, 0.008958570077084005, -0.009101474541239 44, -0.05231658130651 34, -0.026516	Tibial anterior - Pierna derecha
Group Name #25	Sensor 1	[-0.01909899924066849, 0.007668566890060902, -0.016518992866622284, -0.012003981712041423, -0.007166469760704786, 0.005	Tibial anterior - Pierna derecha
Group Name #26	Sensor 1	[0.007023565296549 35, -0.015551490476354957, 0.0041210581257473 68, 0.015731086808955297, 0.039273644972216 93, 0.048626	Tibial anterior - Pierna derecha
Group Name #27	Sensor 1	[-0.0032964601995 35476, 0.006701064499793574, -0.0013614554191008 21, 0.0044435589225031435, 0.013796082028420642, 0.01	Tibial anterior - Pierna derecha
Group Name #28	Sensor 1	[-0.0023289578093681484, 0.0012185509549453855, -0.03199903111089952, -0.021034004021203145, -0.02135650481795892, -0.0	Tibial anterior - Pierna derecha
Group Name #29	Sensor 1	[0.006701064499793574, -0.020711503224447 37, -0.022646508004982024, -0.004263962589902803, -0.013616485695820302, -0.01	Tibial anterior - Pierna derecha
Group Name #30	Sensor 1	[-0.013293984899064526, 0.0002510485646780 5803, 0.005411061312770471, -0.010713978525018321, 0.015086085215443745, -0.00	Tibial anterior - Pierna derecha
Group Name #31	Sensor 1	[-0.024259011988760903, -0.0007164538255892694, -0.017808996053645387, -0.03554653987521306, -0.01458398808608763, -0.00	Tibial anterior - Pierna derecha
Group Name #32	Sensor 1	[-0.007811471354216337, -0.023614010395249352, -0.026194016769295 56, -0.018453997647159 64, 0.003798557328991592, 0.0057	Tibial anterior - Pierna derecha
Group Name #33	Sensor 1	[-0.020389002427691594, -0.047156568558420986, -0.004908964183414355, -0.011036479321774095, -0.0013614554191008 21, -0.0	Tibial anterior - Pierna derecha
Group Name #34	Sensor 1	[0.0031535557354800403, -0.004908964183414355, 0.017343590792734176, 0.008636069280328229, -0.0026514586061239243, -0.0	Tibial anterior - Pierna derecha
Group Name #35	Sensor 1	[0.004766059719258919, 0.049271169671555 98, -0.0003939530288334936, -0.0026514586061239243, -0.007488970557460561, 0.0	Tibial anterior - Pierna derecha
Group Name #36	Sensor 1	[0.03604863700456917, 0.023148605134338 14, 0.023471105931093916, 0.013796082028420642, 0.022826104337582365, 0.016698	Tibial anterior - Pierna derecha
Group Name #37	Sensor 1	[0.027341115492163226, 0.016053587605711073, -0.011036479321774095, 0.022503603540826 59, -0.0036189609963912517, -0.00	Tibial anterior - Pierna derecha
Group Name #38	Sensor 1	[0.007668566890060902, 0.007668566890060902, 0.014763584418687 97, -0.016518992866622284, -0.003296460199635476, 0.0076	Tibial anterior - Pierna derecha
Group Name #39	Sensor 1	[-0.0039414617931470275, -0.1229442557960283, -0.14584181236568838, -0.03748154465574771, -0.012326482508797199, 0.0012	Tibial anterior - Pierna derecha
Group Name #40	Sensor 1	[-0.014906488882843405, -0.021034004021203145, -0.017486495256889 61, 0.000573549361433 8338, -0.02522651437902823, 0.017	Tibial anterior - Pierna derecha
Group Name #41	Sensor 1	[0.008958570077084005, -0.0016839562158565968, -0.024581512785516 68, 0.005088560516014695, -0.022646508004982024, -0.03	No útil
Group Name #42	Sensor 1	[-0.014583988086 08763, -0.025549015175784007, -0.023936511192005128, -0.012003981712041423, -0.005231464980170131, -0.0	Tibial anterior - Pierna derecha
Group Name #43	Sensor 1	[0.01702108999597 84, 0.021858601947315037, 0.013151080434904 09, -0.007166469760704786, -0.007488970557460561, -0.00619	No etiquetado
Group Name #44	Sensor 1	[-0.007488970557460561, 0.010248573264107108, -0.025549015175784007, -0.001683956215856 5968, 0.06797621588339098, 0.075	Pantorrilla - Pierna derecha
Group Name #45	Sensor 1	[-0.030064026330364868, 0.006056062906282023, -0.011358980118529871, -0.003296460199635476, -0.019421500037424266, 0.00	Pantorrilla - Pierna derecha
Group Name #46	Sensor 1	[-0.030709027923876 42, 0.010248573264107108, 0.039273644972126 93, 0.030566123459720984, 0.024116107524605468, -0.00619	Pantorrilla - Pierna derecha
Group Name #47	Sensor 1	[0.036371137801324 95, 0.004766059719258919, 0.002831054938724 2645, -0.018776498443912715, 0.006378563703037798, 0.0099	Pantorrilla - Pierna derecha
Group Name #48	Sensor 1	[-0.012003981712041423, 0.004121058125747368, -0.010391477728262544, 0.003476056532235816, -0.013938986492576078, -0.01	Pantorrilla - Pierna derecha
Group Name #49	Sensor 1	[-0.003296460199635476, -0.004586463386658579, -0.008778973744483665, 0.013151080434904909, 0.029598621069453657, -0.007	Pantorrilla - Pierna derecha
Group Name #50	Sensor 1	[0.006701064499793574, -0.000939353028833936, -0.026516517566051334, 0.011216075654374436, 0.029598621069453657, -0.01	Pantorrilla - Pierna derecha
Group Name #51	Sensor 1	[-0.03393403589143418, -0.009423975337995216, -0.019421500037424266, 0.005088560516014695, -0.034901538281701505, 0.001	Pantorrilla - Pierna derecha
Group Name #52	Sensor 1	[0.006056062906282023, 0.0263736131018959, 0.020246097963536158, -0.007488970557460561, -0.007166469760704786, 0.02508	Pantorrilla - Pierna derecha
Group Name #53	Sensor 1	[0.07216872624121606, 0.08571375970495865, 0.08184375014388934, 0.036371137801324 95, 0.03604863700456917, 0.023148605	Pantorrilla - Pierna derecha
Group Name #54	Sensor 1	[-0.0052314649801701 31, 0.011861077247885987, -0.014583988086087 63, -0.013616485695820302, -0.004263962589902803, -0.00	Pantorrilla - Pierna derecha
Group Name #55	Sensor 1	[-0.019421500037424266, -0.005876466573681682, -0.05199408050975762, -0.031999031110899 52, -0.035224039078457 28, -0.019	Pantorrilla - Pierna derecha
Group Name #56	Sensor 1	[-0.038771547842770815, 0.018311093183001503, -0.001038954622345045 2, 0.010248573264107108, -0.010713978525018321, 0.019	Pantorrilla - Pierna derecha
Group Name #57	Sensor 1	[-0.079406648233998 57, -0.018453997647159 64, 0.014118582825176418, 0.030243622662965 21, -0.007811471354216337, -0.03070	Pantorrilla - Pierna derecha
Group Name #58	Sensor 1	[-0.015551490476354957, 0.024438608321361244, -0.009746476134750992, 0.018311093183001503, 0.04153115054941736, -0.0049	Pantorrilla - Pierna derecha
Group Name #59	Sensor 1	[-0.017486495256888961, -0.024259011988760903, -0.025226514379028 23, 0.026696113898651674, 0.001218550954945385 5, 0.0079	Pantorrilla - Pierna derecha

Group Name #60	Sensor 1	[-0.02619401676929556, -0.024904013582272455, -0.022646508004982024, -0.04941407413571142, 0.011538576451130211, 0.0025	Pantorrilla - Pierna derecha
Group Name #61	Sensor 1	[-0.038771547842770815, -0.01845399764715694, -0.027161519159562886, -0.008778973744483665, -0.01845399764715694, -0.07	Pantorrilla - Pierna derecha
Group Name #62	Sensor 1	[-0.09262918090098538, -0.09617668966529891, -0.02845152234658599, 0.026696113898651674, 0.014441083621932194, 0.03121	Pantorrilla - Pierna derecha
Group Name #63	Sensor 1	[0.0028310549387242645, 0.0005735493614338338, 0.0015410517517011613, -0.007811471354216337, -0.0036189609963912517, -	Pantorrilla - Pierna derecha
Group Name #64	Sensor 1	[-0.006198967370437458, -0.002006457012612372 6, -0.009746476134750992, -0.018131496850401163, -0.04747906935517676, -0.0	Pantorrilla - Pierna derecha
Group Name #65	Sensor 1	[-0.021034004021203145, 0.005411061312770471, 0.003798557328991592, -0.022001506411470473, 0.007668566890060902, 0.013	Pantorrilla - Pierna derecha
Group Name #66	Sensor 1	[-0.0029739594028797, -0.022001506411470473, -0.019421500037424266, -0.019421500037424266, -0.021356504817958892, -0.024	Pantorrilla - Pierna izquierda
Group Name #67	Sensor 1	[-0.013616485695820302, -0.017163994460133836, -0.023936511192005128, -0.013938986492576078, -0.01748649525688961, -0.0	Pantorrilla - Pierna izquierda
Group Name #68	Sensor 1	[0.04024114736239426, 0.03766114098834805, 0.046368662500754, 0.07184622544446029, 0.034758633817546 07, 0.061526199948	Pantorrilla - Pierna izquierda
Group Name #69	Sensor 1	[-0.07908414743724279, -0.028129021549830213, 0.004766059719258919, 0.028953619475942105, 0.016053587605711073, -0.019	Pantorrilla - Pierna izquierda
Group Name #70	Sensor 1	[-0.010068976931506768, 0.04411115692346357, 0.020891099557047 71, 0.006701064499793574, -0.006198967370437458, 0.00863	Pantorrilla - Pierna izquierda
Group Name #71	Sensor 1	[0.010571074060862884, -0.028129021549830213, -0.0020064570126123726, 0.003798557328991592, -0.0039414617931470275, -0.	Pantorrilla - Pierna izquierda
Group Name #72	Sensor 1	[-0.019421500037424266, -0.027161519159562886, -0.008778973744483665, -0.018131496850401163, -0.026516517566051334, 0.0	Pantorrilla - Pierna izquierda
Group Name #73	Sensor 1	[0.022181102744070813, -0.009423975337995216, -0.012326482508797199, -0.018453997647156 94, -0.0010389546223450452, -0.0	Pantorrilla - Pierna izquierda
Group Name #74	Sensor 1	[-0.018131496850401163, -0.040384051826549694, -0.036191541468724 61, -0.018776498443912715, 0.008313568483572453, 0.000	Pantorrilla - Pierna izquierda
Group Name #75	Sensor 1	[0.008958570077084005, -0.023614010395249352, 0.012828579638153315, 0.004443558922503 1435, -0.024581512785516 68, -0.003	Pantorrilla - Pierna izquierda
Group Name #76	Sensor 1	[-0.033289034297922626, 0.005411061312770471, 0.019601096370024607, 0.021213600353803486, -0.0020064570126123726, 0.01	Pantorrilla - Pierna izquierda
Group Name #77	Sensor 1	[0.007991067686816677, 0.015731086808955297, 0.024438608321361244, -0.023291509598493576, -0.03296653350116685, 0.0476	Pantorrilla - Pierna izquierda
Group Name #78	Sensor 1	[-0.020389002427691594, -0.0023289578093681484, 0.006701064499793574, -0.015551490476354957, -0.007811471354216337, -0.	Pantorrilla - Pierna izquierda
Group Name #79	Sensor 1	[-0.02071150322444737, 0.020246097963536158, -0.008456472947727889, -0.005231464980170131, -0.015873991273110732, 0.003	Pantorrilla - Pierna izquierda
Group Name #80	Sensor 1	[-0.009423975337995216, -0.01297148410230875, -0.02071150322444737, -0.037159043858991936, -0.043286558997351676, -0.00	Pantorrilla - Pierna izquierda
Group Name #81	Sensor 1	[-0.03167653031414375, 0.040563648159150034, 0.030566123459720984, 0.021536101155055926, 0.0025085541419684887, 0.00605	Pantorrilla - Pierna izquierda
Group Name #82	Sensor 1	[0.055076184013159946, 0.13408887921832502, 0.0944212812173646, 0.08861626687576063, 0.11898884416107088, 0.132153874 4	Pantorrilla - Pierna izquierda
Group Name #83	Sensor 1	[0.006701064499793574, -0.010391477728262544, -0.0055539657769259065, -0.004908964183414355, -0.005231464980170131, -0.	Pantorrilla - Pierna izquierda
Group Name #84	Sensor 1	[-0.042641557403840125, -0.002006457012612372 6, -0.021679005614714697, 0.062493702338542 79, 0.0944212812173646, 0.0641(	Pantorrilla - Pierna izquierda
Group Name #85	Sensor 1	[0.04540116011048667, 0.018633593979757 28, 0.005088560516014695, 0.0018635552548456937, 0.005411061312770471, -0.012003	Pantorrilla - Pierna izquierda
Group Name #86	Sensor 1	[-0.018776498443912715, 0.03379113142727874, 0.005733562109526247, 0.011538576451130211, -0.017808996053645387, -0.0039	Pantorrilla - Pierna izquierda
Group Name #87	Sensor 1	[-0.008456472947727889, -0.011358980118529871, -0.004908964183414355, -0.007811471354216337, -0.03780404545250349, -0.0	No etiquetado