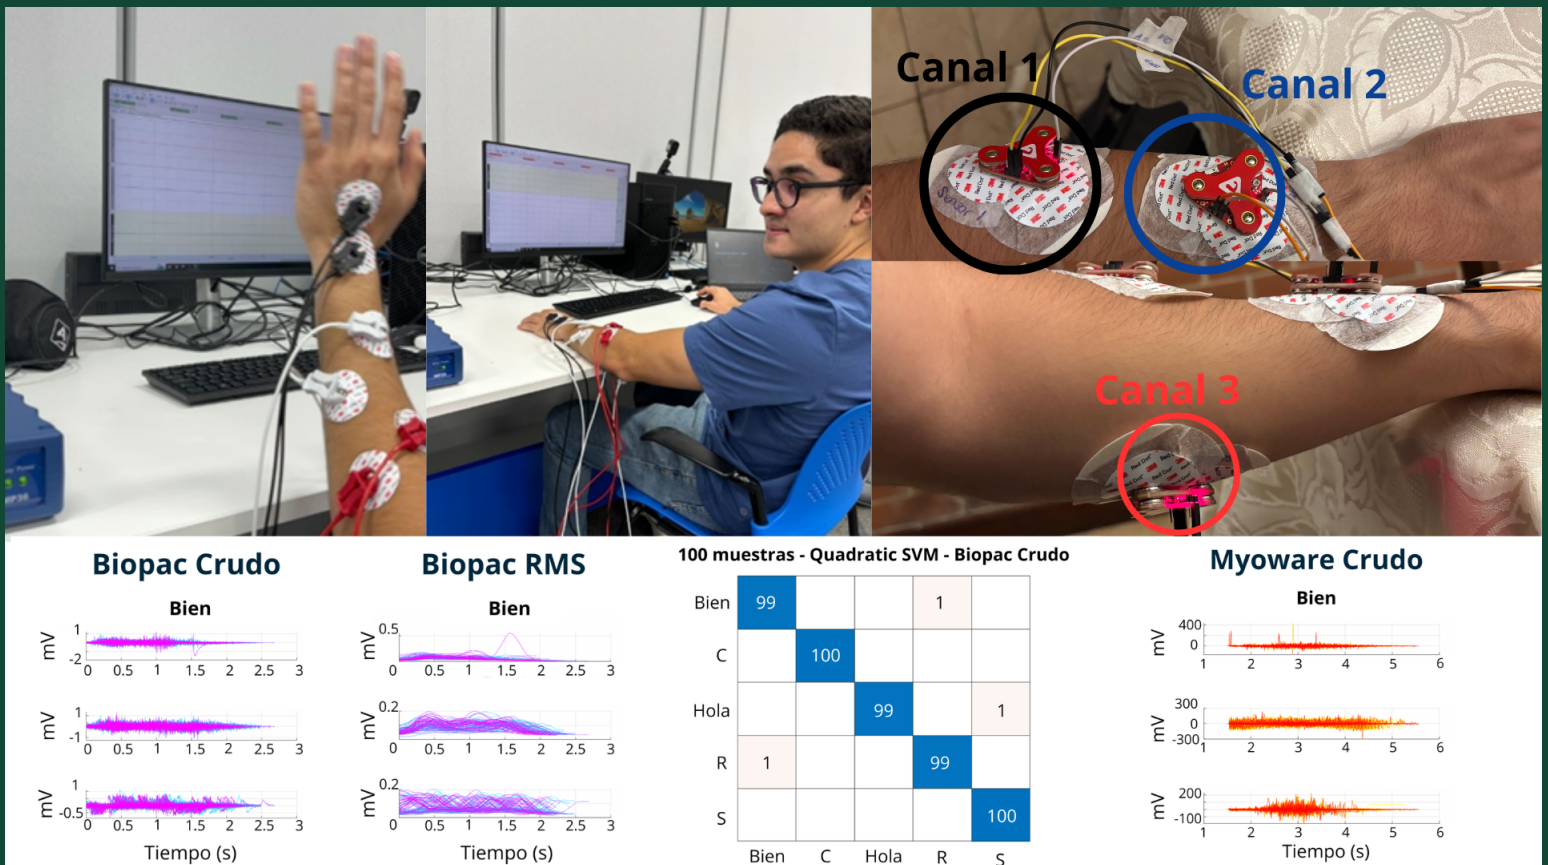


Sistema de reconocimiento del lenguaje de señas en español mediante señales electromiográficas y *machine learning*

Ernesto Salvador Chavez González



UNIVERSIDAD DEL VALLE DE GUATEMALA
Facultad de Ingeniería



Sistema de reconocimiento del lenguaje de señas en español
mediante señas
electromiográficas y *machine learning*

Trabajo de graduación presentado por Ernesto Salvador Chavez
González para optar al grado académico de Licenciado en Ingeniería
Biomédica

Guatemala,

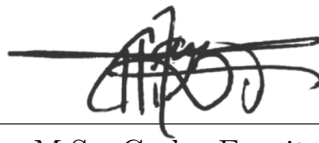
2025

Vo.Bo.:



(f)

Dr.-Ing. José Leal



(f)

M.Sc. Carlos Esquit

Desde que inicié la carrera de Ingeniería Biomédica, sentí una profunda motivación por aprovechar la tecnología para transformar la medicina y mejorar la vida de las personas. Este trabajo nace de esa inquietud y de la convicción de que la innovación puede derribar las barreras que limitan la comunicación y abrir oportunidades de inclusión para las personas con discapacidad auditiva, especialmente en contextos con recursos limitados como Guatemala. Representa la culminación de una meta que soñé durante años, un reto que me exigió lo mejor de mí y una contribución que espero sirva de base para futuros estudios.

Agradezco, ante todo, a Dios, por haberme permitido estudiar la carrera que siempre anhelé, por acompañarme en cada paso y por darme la fuerza necesaria para alcanzar este logro. A mis padres, por ser el corazón de mi esfuerzo y creer en mí sin condiciones; su apoyo y amor constantes me dieron la fortaleza para seguir adelante incluso en los momentos más difíciles. A mis hermanos, por estar siempre presentes con ánimo y compañía; a mis abuelitos, por su cariño, sus sabios consejos y el ejemplo que representan en mi vida; y a mis amigos, por su comprensión y apoyo incondicional durante este proceso.

Extiendo también mi más sincero agradecimiento al Dr.-Ing. José Andrés Leal, cuya guía, paciencia y compromiso fueron esenciales para la realización de este proyecto. Del mismo modo, reconozco el apoyo de los técnicos de laboratorio y de cada profesor que, con su orientación, me ayudaron a superar obstáculos y continuar aprendiendo con entusiasmo.

Este proyecto simboliza el cierre de una etapa inolvidable, llena de aprendizajes, esfuerzo y satisfacción. Más que el final de un camino académico, es el comienzo de nuevos desafíos que enfrento con gratitud y el firme deseo de seguir aportando al bienestar de los demás.

Prefacio	I
Índice de figuras	VI
Índice de cuadros	VII
Resumen	VIII
Abstract	IX
1. Introducción	1
2. Antecedentes	2
3. Justificación	4
4. Objetivos	6
4.1. Objetivo general	6
4.2. Objetivos específicos	6
5. Alcance	7
6. Marco teórico	8
6.1. Actividad eléctrica muscular	8
6.2. Medición de EMG	9
6.3. Parámetros importantes de EMG	11
6.4. <i>Machine learning</i>	13
6.5. Algoritmos de <i>machine learning</i>	13
6.6. <i>Machine learning</i> en la Ingeniería Biomédica	15
6.7. <i>Machine learning</i> para EMG	17
6.8. Lenguaje de señas en Guatemala	17

7. Metodología	19
7.1. Colocación de electrodos	19
7.2. Obtención de señales EMG	20
7.3. Procesamiento de las señales EMG	22
7.4. Entrenamiento de modelos de aprendizaje automático	24
7.5. Implementación y validación del modelo seleccionado	28
8. Resultados	29
8.1. Set de datos de señales EMG crudas/RMS - BIOPAC	29
8.2. Set de datos de señales EMG crudas – MyoWare muscle sensor 2.0	31
8.3. Entrenamiento de modelos de <i>machine learning</i> con set de datos en crudo de BIOPAC	32
8.4. Entrenamiento de modelos de <i>machine learning</i> con set de datos RMS de BIOPAC	33
8.5. Entrenamiento de modelos de <i>machine learning</i> con el set de datos en crudo de MyoWare Muscle Sensor 2.0	35
8.6. Precisión según cantidad de canales usados	37
8.7. Etapa de validación de modelos	39
9. Discusión	45
9.1. Morfología y reproducibilidad de las señales EMG	45
9.2. Desempeño de los modelos de <i>machine learning</i> con señales crudas – BIOPAC MP36	46
9.3. Desempeño de los modelos de <i>machine learning</i> con señales RMS – BIOPAC MP36	47
9.4. Desempeño de los modelos de <i>machine learning</i> con señales crudas – Myoware Muscle Sensor 2.0	48
9.5. Desempeño de los modelos de <i>machine learning</i> ante la disminución de canales para entrenamiento	48
9.6. Validación de los modelos con precisión más alta	49
10. Conclusiones	50
11. Recomendaciones	52
11.1. Identificación de limitaciones actuales	52
11.2. Propuestas concretas de mejora o investigación	53
12. Referencias	56
13. Anexos	62

1.	A. Sinapsis eléctrica y uniones en hendidura permeables a iones y moléculas pequeñas [17]. B. Diagrama esquemático de un potencial de acción [18]	9
2.	Modelo esquemático y de circuito eléctrico equivalente de la interfaz electrodo-piel para electrodos húmedos [20]	9
3.	Electrodo seco portátil integrado en brazalete WyoFlex [21]	10
4.	Electrodo seco portátil integrado en brazalete WyoFlex [20]	10
5.	Electrodo intramuscular y aguja para colocación [23]	11
6.	Representación temporal de la señal EMG y de las características MAV, RMS, VAR, SSC, ZC y WA [26]	12
7.	Representación del método STFT aplicado a una señal EMG durante una tarea estática. [28]	12
8.	Etapas típicas en el desarrollo de un modelo ML como un SVM para resolver un problema de clasificación o regresión [31]	13
9.	Estructura general del modelo KNN [33]	14
10.	Comparación entre (a) red superficial y (b) red neuronal profunda [34]	14
11.	Diagrama de flujo del método de aprendizaje automático de <i>Gradient Boosting</i> [36]	15
12.	Matriz de confusión que compara el desempeño de un modelo CNN con dos dermatólogos especializados en la clasificación de lesiones cutáneas, ilustrando un ejemplo del uso de <i>machine learning</i> en imagen médica [37]	15
13.	Curvas de comparación entre radiólogos y algoritmos de <i>machine learning</i> para detección de patologías pulmonares [38]	16
14.	Colocación de electrodos en el antebrazo izquierdo en los músculos: <i>Flexor Carpi Radialis</i> (V+_1), <i>Palmar Largo</i> (V-_1), <i>Pronador Cuadrado</i> (V+_2), <i>Extensor Digitorum</i> (V-_2), <i>Braquiorradial</i> (V+_3), y <i>Flexor Digital de los Dedos</i> (V-_3)	19
15.	Colocación de los sensores MyoWare Muscle Sensor 2.0 en el antebrazo izquierdo	20
16.	Señas realizadas y sus gestos correspondientes	20
17.	Diagrama del gesto Bien con 30 segundos de medición basal previo a la ejecución del gesto y conexión para la obtención de las señales EMG correspondientes a las señas escogidas del LENSEGUA	21
18.	Conexión de sensores MyoWare Muscle Sensor 2.0 con Arduino UNO	22

19.	Rectificación absoluta de la señal EMG y envolvente RMS de la señal rectificada	23
20.	Procesamiento de la señal EMG en crudo mediante filtro pasabanda Butterworth de cuarto orden	24
21.	Ejemplo ilustrativo de una señal EMG donde se muestran las características utilizadas como parámetros de entrada: <i>slope sign changes</i> (SSC), <i>waveform length</i> (WL), media y varianza	25
22.	Ilustración de las características del dominio de la frecuencia empleadas como parámetros de entrada: <i>zero crossings</i> (ZC), <i>frecuencia media</i> (MF), frecuencia mediana (MDF), <i>root mean square</i> (RMS) y <i>mean absolute value</i> (MAV)	26
23.	Secuencia de entrenamiento y validación de modelos de Machine Learning	28
24.	Señales en crudo (columna 1) y RMS (columna 2) superpuestas obtenidas con BIOPAC MP36. El número de muestras por seña es de 100. En forma descendente se encuentra “Bien”, “C”, “Hola”, “R” y “S”	30
25.	Señales EMG crudas superpuestas registradas con tres sensores Myoware Muscle Sensor 2.0. El número de muestras por seña es de 100. Primera fila, de izquierda a derecha: “Bien”, “C”, “Hola”. Segunda fila, de izquierda a derecha: “R” y “S”	31
26.	Resultados de precisión de los modelos de <i>machine learning</i> entrenados con el conjunto de datos crudo de BIOPAC	32
27.	Matrices de confusión (MC) de los modelos con mayor rendimiento para el set de datos en crudo con 100 muestras por seña, 50 muestras por seña y 25 muestras por seña	33
28.	Resultados de precisión de los modelos de <i>machine learning</i> entrenados con el con set de datos RMS de BIOPAC	34
29.	Matrices de confusión (MC) de los modelos con mayor rendimiento para el set de datos RMS con 100 muestras por seña, 50 muestras por seña y 25 muestras por seña	35
30.	Resultados de precisión de los modelos de <i>machine learning</i> entrenados con el set de datos en crudo de Myoware	36
31.	Resultados de precisión de los modelos de <i>machine learning</i> entrenados con el set de datos en crudo de Myoware	36
32.	Precisión de los modelos de <i>machine learning</i> entrenados con el set de datos de 100 muestras por seña en señales EMG crudas, evaluados según la cantidad de canales de adquisición utilizados	37
33.	Precisión de los modelos de <i>machine learning</i> entrenados con el set de datos RMS con 100 muestras por seña, evaluados según la cantidad de canales de adquisición utilizados	38
34.	Precisión de los modelos de <i>machine learning</i> entrenados con el set de datos MyoWare crudo (100 muestras por seña), evaluados según la cantidad de canales de adquisición utilizados	39
35.	Validación de <i>Cubic SVM</i> entrenado con 100 muestras crudas por seña (BIOPAC MP36) al ser probado con un nuevo set de datos	40
36.	Validación de <i>Linear Discriminant</i> entrenado con 100 muestras crudas por seña (BIOPAC MP36) al ser probado con un nuevo set de datos	41
37.	Validación de <i>Quadratic SVM</i> entrenado con 100 muestras crudas por seña (BIOPAC MP36) al ser probado con un nuevo set de datos	42

38.	Validación de Quadratic SVM entrenado con 100 muestras RMS por seña (BIOPAC MP36) al ser probado con un nuevo set de datos	43
39.	Validación de <i>Medium Gaussian SVM</i> entrenado con 100 muestras crudas por seña (MyoWare Muscle Sensor 2.0) al ser probado con un nuevo set de datos	44
40.	Comparación general de aciertos y errores en la etapa de validación de los modelos de clasificación	44
41.	Flujo del proceso de recalibración entre sesiones para el reconocimiento de señas EMG en tiempo real	53
42.	Propuesta de mejora del sistema de adquisición EMG mediante ADC externo de alta resolución	54
43.	Sistema de adquisición y traducción en tiempo real de señas EMG	55
44.	Resultados de precisión de los modelos de <i>machine learning</i> entrenados con el conjunto de datos crudo de BIOPAC (100 muestras por seña)	62
45.	Resultados de precisión de los modelos de <i>machine learning</i> entrenados con el conjunto de datos crudo de BIOPAC (50 muestras por seña)	63
46.	Resultados de precisión de los modelos de <i>machine learning</i> entrenados con el conjunto de datos crudo de BIOPAC (25 muestras por seña)	64
47.	Resultados de precisión de los modelos de <i>machine learning</i> entrenados con el conjunto de datos RMS de BIOPAC (100 muestras por seña)	65
48.	Resultados de precisión de los modelos de <i>machine learning</i> entrenados con el conjunto de datos RMS de BIOPAC (50 muestras por seña)	66
49.	Resultados de precisión de los modelos de <i>machine learning</i> entrenados con el conjunto de datos RMS de BIOPAC (25 muestras por seña)	67
50.	Resultados de precisión de los modelos de <i>machine learning</i> entrenados con el conjunto de datos en crudo de MyoWare (100 muestras por seña)	68
51.	Resultados de precisión de los modelos de <i>machine learning</i> entrenados con el conjunto de datos en crudo de MyoWare (50 muestras por seña)	69
52.	Resultados de precisión de los modelos de <i>machine learning</i> entrenados con el conjunto de datos en crudo de MyoWare (25 muestras por seña)	70

Índice de cuadros

1.	Parámetros y descripción de características de la señal EMG en RMS	25
2.	Parámetros y descripción de características en el dominio de la frecuencia para set de datos en crudo	25
3.	Algoritmos de entrenamiento de <i>machine learning</i> de la aplicación <i>Classifica- tion Learner</i>	27

La pérdida auditiva afecta a más de 430 millones de personas en el mundo y a unas 250 000 en Guatemala, donde la Lengua de Señas Guatemalteca (LENSEGUA) constituye el principal medio de comunicación de la comunidad con discapacidad auditiva. Sin embargo, la mayoría de la población oyente desconoce este sistema, lo que genera barreras educativas, laborales y de atención sanitaria. Las soluciones tecnológicas existentes suelen requerir condiciones poco accesibles y de alto costo, por lo que resultan de adopción limitada en entornos de bajos recursos. Ante esta brecha, se propone una alternativa electromiográfica que aprovecha la disponibilidad de sensores de bajo costo y algoritmos de aprendizaje automático para traducir señas básicas en tiempo real.

En este proyecto se investigó el desarrollo de un sistema autónomo de reconocimiento de LENSEGUA basado en señales electromiográficas. Tres canales registraron la actividad electromiográfica de los músculos del antebrazo mediante un sistema BIOPAC MP36; las señales fueron filtradas y rectificadas en MATLAB para generar un conjunto de 100 segmentos crudos y 100 segmentos RMS por cada una de las cinco señas seleccionadas (Hola, Bien, C, R y S). Además, se obtuvo un set de datos crudos utilizando sensores MyoWare Muscle Sensor 2.0 conectados a un Arduino Uno, con la adquisición y almacenamiento de los datos controlados mediante Python, registrando igualmente 100 muestras por seña. Con ambos conjuntos de datos se entrenaron y compararon modelos de *machine learning*, seleccionando los que alcanzaron las mayores precisiones. Finalmente, los modelos con mejor desempeño fueron validados utilizando nuevos registros independientes obtenidos bajo las mismas condiciones experimentales, con el fin de evaluar su capacidad de clasificación.

Keywords: electromiografía, lenguaje de señas, machine learning, matriz de confusión, procesamiento de señales.

Hearing loss affects more than 430 million people worldwide and approximately 250,000 in Guatemala, where the Guatemalan Sign Language (LENSEGUA) constitutes the main means of communication for the deaf and hard-of-hearing community. However, most of the hearing population is unfamiliar with this system, creating educational, occupational, and healthcare barriers. Existing technological solutions often require costly and non-accessible conditions, which limits their adoption in low-resource environments. To address this gap, an electromyographic alternative is proposed, taking advantage of the availability of low-cost sensors and machine learning algorithms to translate basic signs in real time.

In this project, the development of an autonomous recognition system for LENSEGUA based on electromyographic signals was investigated. Three channels recorded the electromyographic activity of forearm muscles using a BIOPAC MP36 system; the signals were filtered and rectified in MATLAB to generate a set of 100 raw segments and 100 RMS segments for each of the five selected signs (Hola, Bien, C, R, and S). In addition, a raw dataset was obtained using MyoWare Muscle Sensor 2.0 sensors connected to an Arduino Uno, with data acquisition and storage controlled through Python, also recording 100 samples per sign. Both datasets were used to train and compare machine learning models, selecting those that achieved the highest accuracies. Finally, the best-performing models were validated using new independent recordings obtained under the same experimental conditions in order to assess their classification capability.

Keywords: electromyography, sign language, machine learning, confusion matrix, signal processing.

La pérdida auditiva es uno de los desafíos de inclusión más relevantes a nivel mundial, ya que afecta la comunicación, la educación y la integración social. En Guatemala, la comunidad sorda utiliza la Lengua de Señas Guatemalteca (LENSEGUA) como principal medio de expresión; sin embargo, la poca familiaridad de la población oyente limita la interacción diaria. Aunque existen tecnologías de asistencia, muchas requieren infraestructura costosa o difícil de implementar en contextos con recursos limitados. Este proyecto busca ofrecer una solución práctica y accesible mediante herramientas basadas en electromiografía y aprendizaje automático para reducir estas barreras comunicativas.

Para ello, se desarrolló un sistema experimental de reconocimiento de señas en español utilizando señales electromiográficas (EMG) obtenidas de los músculos del antebrazo. Las señas se adquirieron con BIOPAC MP36 y MyoWare Muscle Sensor 2.0, se procesaron digitalmente en MATLAB y se clasificaron con distintos algoritmos de *machine learning*. El procesamiento incluyó filtrado, rectificación, cálculo RMS y entrenamiento supervisado con validación cruzada, analizando la influencia del tipo de señal, del sensor y del número de canales en la precisión. Los modelos con mejor desempeño se evaluaron con nuevos conjuntos de datos para comprobar su capacidad de generalización y su utilidad como herramienta de comunicación accesible.

Los capítulos 2 y 3 presentan los antecedentes y la justificación del proyecto. El capítulo 4 expone los objetivos y el 5 delimita el alcance experimental. El capítulo 6 desarrolla el marco teórico sobre electromiografía y *machine learning*, seguido de la metodología en el capítulo 7. Los resultados se analizan en el capítulo 8 y se discuten en el 9. Finalmente, los capítulos 10 y 11 incluyen conclusiones, recomendaciones, referencias y anexos.

El lenguaje de señas es un sistema lingüístico de carácter visual, espacial, gestual y manual en cuya conformación intervienen factores históricos, culturales, lingüísticos y sociales. Es un medio de comunicación entre personas con discapacidades auditivas y oyentes [1]. El lenguaje de señas guatemalteco, llamado LENSEGUA, es la lengua gestual que utilizan las personas con discapacidades auditivas de Guatemala. Se estima que esta lengua cuenta con más de cien mil usuarios signantes [2]. Además, la investigación ha buscado interpretar las señas mediante soluciones tecnológicas como guantes con sensores, cámaras de visión por computador y algoritmos de aprendizaje automático, que traducen los movimientos de manos y brazos a texto o voz en tiempo real [3].

La electromiografía (EMG) es una técnica utilizada para registrar el voltaje generado por los músculos en respuesta a la estimulación del sistema nervioso. En el campo de la Ingeniería Biomédica, la EMG se emplea ampliamente en aplicaciones médicas y tecnológicas, incluyendo el diagnóstico de trastornos neuromusculares, la rehabilitación de pacientes con discapacidad motriz y el desarrollo de interfaces hombre-máquina [4].

En el ámbito de la electromiografía, se utilizan diversos sensores para registrar la actividad eléctrica de los músculos. Entre los más destacados se encuentran los sistemas de alta gama como BIOPAC MP36 (BIOPAC Systems Inc.), que permiten una adquisición precisa de señales EMG y son ampliamente utilizados en entornos de investigación debido a su robustez y precisión. Por otro lado, existen opciones más asequibles como el MyoWare 2.0 (Advancer Technologies LLC), diseñado para aplicaciones portátiles y proyectos de bajo costo, facilitando la integración en dispositivos embebidos y aplicaciones de interfaces hombre-máquina. Un estudio reciente comparó la eficacia de ambos dispositivos en la clasificación de gestos del lenguaje de señas polaco, utilizando técnicas de aprendizaje automático como redes neuronales convolucionales (CNN) y otros modelos de *machine learning*. Los resultados mostraron que, aunque el BIOPAC MP36 ofreció una precisión ligeramente superior, el MyoWare 2.0 logró desempeños competitivos [5].

La electromiografía superficial (sEMG) ha sido ampliamente utilizada para el reconocimiento de gestos de la mano. En una revisión sistemática reciente, identificaron al Myo

Armband como un dispositivo altamente efectivo en sistemas de reconocimiento de señas debido a su costo accesible y facilidad de uso, aunque dispositivos más avanzados como BIOPAC también han sido empleados por su alta precisión y capacidad multicanal [6]. Por otro lado, se demostró que los algoritmos de aprendizaje automático, como *SVM*, *Random Forest* y Naïve Bayes, pueden alcanzar precisiones de hasta 96.43 % al clasificar siete gestos distintos utilizando señales EMG captadas por el Myo Armband, resaltando así su potencial para aplicaciones en interfaces hombre-máquina y control de dispositivos asistivos [7].

El uso del MyoWare 2.0 ha sido explorado en diversas aplicaciones para el reconocimiento de gestos de la mano y la mejora de la comunicación en personas con discapacidad auditiva. Se desarrolló un prototipo utilizando este sensor para capturar señales musculares y analizar movimientos de la mano mediante técnicas de extracción de característica (RMS, media, máximo, etc.), logrando distinguir distintos gestos con precisión [8].

A nivel mundial, más del 5 % de la población, aproximadamente 430 millones de personas, requieren rehabilitación para corregir una pérdida de audición discapacitante. Se estima que para el año 2050, esta cifra superará los 700 millones de personas, lo que representa una de cada diez personas afectadas por pérdida de audición y/o habla [9]. En Guatemala, según datos del Benemérito Comité Pro-Ciegos y Sordos de Guatemala, alrededor de 250,000 personas viven con algún grado de discapacidad auditiva [10].

Actualmente, las principales soluciones para facilitar la comunicación de personas con discapacidades auditivas incluyen: el uso de lengua de señas, sistemas de amplificación como audífonos, implantes cocleares y tecnologías de asistencia auditiva. Sin embargo, en países como Guatemala, la implementación y difusión de estas herramientas enfrentan desafíos significativos debido a la falta de recursos, mala infraestructura y falta de programas de educación inclusiva que promuevan su uso efectivo en la sociedad. La Red Latinoamericana de Organizaciones No Gubernamentales de Personas con Discapacidad y sus Familias (RIADIS) destaca las barreras, previamente descritas, que enfrentan las personas con discapacidades auditivas y/o del habla en Guatemala, incluyendo la falta de acceso a tecnologías de asistencia y servicios educativos adecuados [11].

Las lenguas de señas son sistemas de comunicación visogestuales que, al igual que las lenguas orales, presentan diversidad y especificidad regional. Cada país o comunidad ha desarrollado su propia lengua de señas, reflejando particularidades culturales y sociales de su entorno. Estas diferencias se manifiestan en aspectos léxicos, gramaticales y sintácticos. El funcionamiento de las lenguas de señas se basa en la combinación de gestos, movimientos de manos, expresiones faciales y posturas corporales para transmitir información. Cada seña representa un concepto o palabra, y la gramática de estas lenguas permite estructurar oraciones completas [12].

La complejidad del lenguaje de señas radica en la necesidad de dominar una gramática y vocabulario específicos, lo cual puede requerir un aprendizaje prolongado y dedicado. Para la población oyente, la principal barrera es la falta de conocimiento y formación en la lengua de señas, lo que limita la comunicación efectiva con personas sordomudas. Esta carencia

puede llevar a la exclusión social de la comunidad sordomuda. Para superar estas barreras, se han desarrollado diversas soluciones tecnológicas. Aplicaciones como Showleap traducen la lengua de señas a voz en tiempo real, facilitando la comunicación bidireccional entre personas sordas y oyentes [13]. Además, herramientas basadas en inteligencia artificial ofrecen traducciones automáticas y generación de contenido en lengua de señas, contribuyendo a una comunicación más fluida y accesible [14].

Este proyecto propone una solución tecnológica innovadora y accesible para superar las barreras de comunicación existentes entre la población sorda y la oyente. Utilizando señales electromiográficas (EMG), captadas mediante sensores MyoWare Muscle Sensor 2.0, y procesadas y clasificadas con un modelo de machine learning adecuado, este sistema será capaz de reconocer e identificar palabras del lenguaje de señas en español, facilitando así una comunicación directa y efectiva. Al traducir las señas de manera inmediata, se eliminan las dificultades derivadas de la falta de conocimiento de estas entre la población general. De esta forma, la tecnología propuesta no solo contribuye a mejorar la integración social de las personas sordomudas en Guatemala y a nivel mundial, sino también impulsa un acceso más amplio y eficiente a herramientas de comunicación inclusiva.

4.1. Objetivo general

Desarrollar un sistema de reconocimiento del lenguaje de señas mediante el análisis de señales EMG y algoritmos de machine learning, que permita identificar señas básicas en español.

4.2. Objetivos específicos

- Definir un banco de señas básicas del lenguaje de señas el español y capturar múltiples muestras de señales electromiográficas (EMG) para cada una de las señas seleccionadas, con el fin de obtener un dataset robusto y representativo que sirva para el entrenamiento de modelos de *machine learning*.
- Desarrollar y entrenar un modelo de *machine learning* en MATLAB, utilizando los datos EMG recolectados para clasificar e identificar cada una de las señas seleccionadas.
- Implementar y evaluar distintos algoritmos (modelos de *machine learning*), seleccionando el modelo que alcance la mejor precisión en pruebas de validación controlada para identificar y traducir señas.

El presente proyecto se centra en el desarrollo de un sistema experimental para el reconocimiento de señas en español a partir de señales electromiográficas (EMG) obtenidas de músculos del antebrazo. El estudio se ejecutó en condiciones de laboratorio controladas y empleó dos sistemas de adquisición comerciales: BIOPAC MP36 y MyoWare Muscle Sensor 2.0.

El alcance del trabajo incluye la adquisición de señales EMG utilizando configuraciones de tres canales con electrodos de superficie, el procesamiento digital básico de las señales (filtrado, rectificación y cálculo del valor RMS), la extracción de características temporales y espectrales, y la clasificación de cinco señas mediante algoritmos supervisados de aprendizaje automático. El análisis se limita a la comparación del desempeño de los modelos bajo las condiciones experimentales establecidas y al uso de validación cruzada interna para verificar la consistencia de los resultados.

No forma parte del alcance la implementación de un dispositivo portátil, la integración con interfaces gráficas, la prueba del sistema en tiempo real, la expansión del vocabulario de señas, ni la validación clínica o en usuarios de la comunidad sorda. Tampoco se considera el análisis de movimiento completo del brazo ni la inclusión de sensores adicionales distintos a los especificados.

El estudio permite evaluar la viabilidad técnica básica del uso de señales EMG para el reconocimiento de señas en español bajo un entorno controlado de laboratorio. Los resultados obtenidos muestran el funcionamiento general del esquema de adquisición, procesamiento y clasificación dentro de los parámetros establecidos en el diseño experimental. El trabajo también delimita las capacidades reales del sistema, evidenciando las condiciones en las que opera adecuadamente y aquellas que quedan fuera de su alcance actual. Finalmente, el proyecto sienta una base metodológica sólida sobre la cual pueden desarrollarse investigaciones futuras orientadas a sistemas más complejos, portátiles o aplicados en escenarios reales de interacción comunicativa.

6.1. Actividad eléctrica muscular

En la contracción voluntaria del músculo esquelético, el proceso electrofisiológico comienza en la unión neuromuscular (NMJ), la cual es una sinapsis especializada que conecta el axón de la neurona motora α con la fibra muscular. Cuando un potencial de acción alcanza la terminal presináptica, la entrada rápida de Ca^{2+} a través de canales de calcio dependientes de voltaje desencadena la exocitosis de vesículas que contienen acetilcolina (ACh). Las moléculas de ACh difunden a través de la hendidura sináptica (≈ 50 nm) y se unen a los receptores nicotínicos (nAChR) situados en la membrana postsináptica, aumentando la permeabilidad al Na^+ y K^+ (Figura 1). El desplazamiento neto de iones despolariza el sarcolema y genera un potencial de placa terminal (EPP) de aproximadamente +15 mV, valor suficiente para superar el umbral y abrir canales de sodio dependientes de voltaje [15].

La despolarización resultante se propaga como un potencial de acción de la fibra muscular (MAP), con una amplitud cercana a 90 mV y una duración de 2–5 ms. Este potencial viaja en ambas direcciones a lo largo del sarcolema a velocidades de 3–5 m s^{-1} y penetra en los túbulos T, donde activa los receptores de dihidropiridina (DHPR). El acoplamiento mecánico de los DHPR con los receptores de rianodina (RyR1) del retículo sarcoplásmico libera Ca^{2+} al citosol, iniciando la interacción actina–miosina y, por ende, la contracción. La relajación se produce cuando las bombas SERCA recapturan Ca^{2+} hacia el retículo. Cada neurona controla un conjunto de fibras musculares denominado *unidad motora*; la descarga repetitiva de la neurona motora genera trenes de potenciales de acción en sus fibras, cuya frecuencia y sincronía determinan la fuerza desarrollada. De esta forma, la actividad eléctrica muscular integra la señal nerviosa y la transforma en trabajo mecánico mediante un ciclo altamente coordinado de eventos iónicos y moleculares (Figura 1) [16].

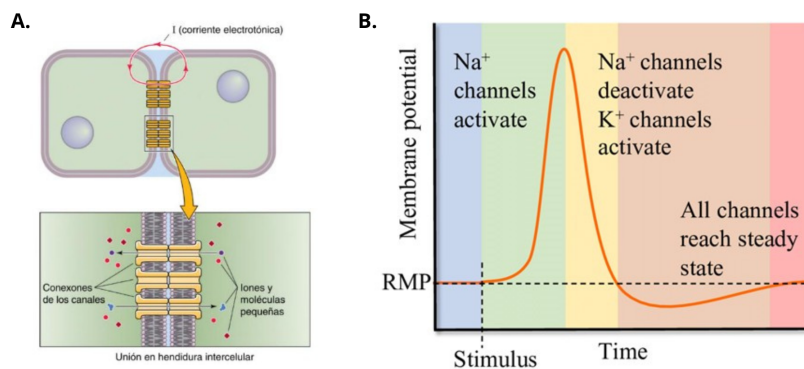


Figura 1. A. Sinapsis eléctrica y uniones en hendidura permeables a iones y moléculas pequeñas [17]. B. Diagrama esquemático de un potencial de acción [18]

6.2. Medición de EMG

El método clásico para registrar EMG superficial emplea electrodos “húmedos” de Ag/AgCl recubiertos con un gel salino (cloruro potásico) (Figura 2). La combinación del electrodo polarizable (plata) con la capa de cloruro genera un par redox reversible que minimiza la polarización electroquímica, ofrece impedancias de contacto inferiores a 5 k Ω y proporciona una línea de base estable durante registros clínicos de corta duración. Su principal desventaja es la necesidad de preparar la piel (raspado y limpieza con alcohol) y renovar el gel después de varias horas, lo que limita su uso en monitorizaciones prolongadas [19].




Figura 2. Modelo esquemático y de circuito eléctrico equivalente de la interfaz electrodo-piel para electrodos húmedos [20]

Para aplicaciones portátiles se han popularizado los electrodos secos metálicos, fabricados en titanio, acero inoxidable o latón niquelado. Al eliminar el gel, estos sensores simplifican la colocación y permiten su integración en brazaletes o textiles inteligentes (Figura 3). Sin embargo, la ausencia de electrolito incrementa la impedancia (>100 k Ω) y los hace más susceptibles al ruido de movimiento; por ello suelen complementarse con circuitos de alta impedancia y un buen blindaje mecánico [21].




Figura 3. Electrodo seco portátil integrado en brazalete WyoFlex [21]

Un paso adicional lo constituyen los electrodos secos flexibles basados en polímeros conductivos (PEDOT/PSS o redes de nanohilos de plata embebidas en poliuretano). Estos *films* ultrafinos se adhieren a la piel y mantienen una impedancia moderada aun sin gel y toleran sudoración, lo que los hace idóneos para registros ambulatorios de larga duración. Las dificultades se concentran en la complejidad de fabricación y en la necesidad de encapsular los *films* para preservar su conductividad con el tiempo (Figura 4) [20].




Figura 4. Electrodo seco portátil integrado en brazalete WyoFlex [20]

Finalmente, los electrodos intramusculares (hilo fino o aguja coaxial) se introducen a través de la fascia para registrar la actividad de una única unidad motora o de un pequeño grupo de fibras (Figura 5). Proporcionan una relación señal-ruido muy favorable y un ancho de banda superior a 1 kHz, por lo que constituyen la herramienta de referencia en electrodiagnóstico y cartografía de unidades motoras. No obstante, requieren personal entrenado, son invasivos y, por definición, inapropiados para sistemas portátiles o de uso cotidiano [22].




Figura 5. Electrodo intramuscular y aguja para colocación [23]

6.3. Parámetros importantes de EMG

La señal electromiográfica se caracteriza mediante atributos temporales, frecuenciales y tiempo–frecuencia que condensan la información fisiológica asociada al reclutamiento y la sincronización de las unidades motoras. Los descriptores de energía, *root mean square* (RMS) y *mean absolute value* (MAV), son proporcionales al número de fibras reclutadas y a la frecuencia de disparo de las unidades motoras. Se calculan sobre ventanas de 100–250 ms para suprimir la variabilidad ciclo a ciclo y ofrecen correlaciones lineales de $r \approx 0.9$ con la fuerza isométrica en contracciones submáximas ($\leq 60\%$ del *maximum voluntary contraction* (MVC)). Fuera de ese rango (fuerzas muy pequeñas o cercanas al 100% MVC) la relación se vuelve menos lineal por factores como la saturación de unidades motoras y la fatiga [24]. Otro índice de amplitud es el *integrated EMG* (IEMG), el cual representa el área bajo la curva y es útil para cuantificar la fatiga cuando se normaliza respecto al tiempo de esfuerzo [22]. La varianza (VAR), por su parte, cuantifica la dispersión de la amplitud de la señal dentro de una ventana y se emplea como un estimador sensible a cambios en la intensidad de activación muscular, especialmente en contracciones dinámicas o con variaciones rápidas en el reclutamiento. La *Willison amplitude* (WA), definida como el número de diferencias sucesivas que superan un umbral preestablecido, actúa como un indicador combinado de amplitud y frecuencia, y se ha asociado a incrementos en la activación muscular y a patrones de disparo más irregulares propios de contracciones rápidas o gestuales.

Los conteos de *zero crossings* (ZC) y *slope sign changes* (SSC) reflejan el contenido de alta frecuencia generado por descargas asincrónicas de fibras rápidas; su aumento indica un mayor reclutamiento de unidades motoras tipo II o una co-contracción antagonista. El descriptor *waveform length* (WL), suma de los módulos de las diferencias muestrales consecutivas, resume simultáneamente la amplitud y la frecuencia, mostrando elevada robustez frente al ruido de movimiento en aplicaciones vestibles (Figura 6) [25].




Figura 6. Representación temporal de la señal EMG y de las características MAV, RMS, VAR, SSC, ZC y WA [26]

En condiciones de fatiga periférica, la conducción axonal se enlentece y el espectro de la señal se desplaza hacia frecuencias más bajas. Los parámetros de referencia son la *medium frequency* (MF) y la *median frequency* (MDF); descensos lineales de $0.5\text{--}1\text{ Hz}\cdot\text{s}^{-1}$ en contracciones sostenidas se correlacionan con el descenso del pH intramuscular y la acumulación de metabolitos. El uso combinado de MDF y RMS permite discernir entre fatiga central (disminución de RMS) y periférica (disminución de MDF) con alta sensibilidad [27].

Para gestos dinámicos, donde la activación muscular varía de forma no estacionaria, se emplean transformadas de corta duración (STFT) (Figura 7) o *continuous wavelet transform* (CWT). La CWT con *wavelets* de Morlet o Daubechies genera “escalogramas” bidimensionales en los que las *convolutional neural networks* (CNN) pueden detectar patrones espacio-temporales complejos; esta estrategia ha permitido precisiones $>95\%$ en la clasificación de macro-gestos de lengua de señas con solo ocho canales EMG [7].




Figura 7. Representación del método STFT aplicado a una señal EMG durante una tarea estática. [28]

En aplicaciones clínicas se calcula el *rate of mean frequency shift* (RMSF) y la coheren-

cia EMG–EMG para evaluar la fatiga o la coordinación intermuscular. Niveles elevados de coherencia en el rango beta (15–30 Hz) sugieren control cortical compartido entre músculos sinérgicos, mientras que reducciones indican descontrol motor o lesiones del sistema nervioso central [29].

6.4. *Machine learning*

El *machine learning* (ML) es una subdisciplina de la inteligencia artificial cuyo objetivo es desarrollar algoritmos que, a partir de un conjunto de datos, infieren patrones y mejoran su desempeño de forma autónoma conforme reciben más información. En lugar de programar reglas fijas, estos sistemas ajustan internamente sus parámetros para minimizar el error entre sus predicciones y los valores reales, formulando el proceso como un problema de optimización donde la función de pérdida se reduce iterativamente. En el ML, el modelo aprende o se enseña a sí mismo ya que su rendimiento medido con una métrica predefinida mejora tras exponerse a la experiencia. El progreso del rendimiento se evalúa mediante una métrica definida que comprueba cómo la exposición continua a los datos incrementa la exactitud del sistema [30].

6.5. Algoritmos de *machine learning*

Los algoritmos de *machine learning* se distinguen por la forma en que representan los datos y resuelven la tarea de predicción. El *Support Vector Machine* (SVM) (Figura 8) formula la clasificación como un problema de optimización convexa: busca el hiperplano que maximiza el margen entre clases y, mediante la técnica del núcleo, proyecta los datos a espacios de mayor dimensión donde la separación lineal sea posible. Esta estrategia ofrece buena generalización aun con conjuntos de entrenamiento moderados y sigue evolucionando en variantes que manejan datos ruidosos y no balanceados[31].

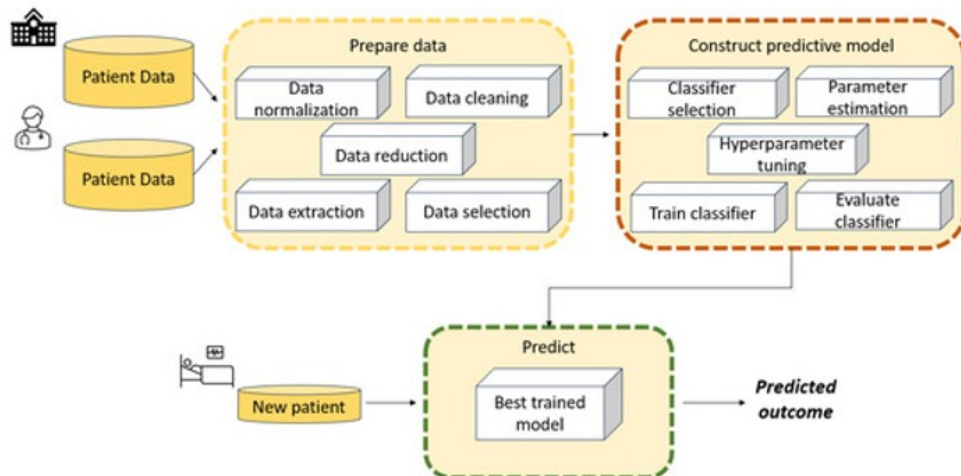


Figura 8. Etapas típicas en el desarrollo de un modelo ML como un SVM para resolver un problema de clasificación o regresión [31]

El *k-Nearest Neighbors* (kNN) (Figura 9) representa el extremo opuesto: es un método no paramétrico y “perezoso” que aplaza el cálculo hasta la fase de consulta; para clasificar un nuevo ejemplo sólo computa distancias con los puntos almacenados y adopta la etiqueta mayoritaria. Sus recientes mejoras se centran en acelerar la búsqueda en espacios de alta dimensión y en escoger dinámicamente el valor óptimo de k , lo que mantiene su vigencia en dominios de series temporales, recomendación y detección de anomalías [32].

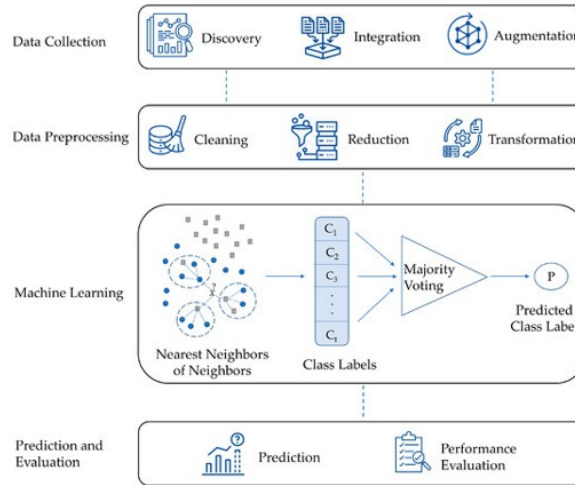


Figura 9. Estructura general del modelo KNN [33]

El auge del *Deep Learning* radica en las redes neuronales profundas, capaces de aprender representaciones jerárquicas con millones de parámetros ajustados por retro-propagación. Las *Convolutional Neural Networks* (CNN) (Figura 10) explotan patrones locales invariantes en datos con estructura espacial, mientras que las *Recurrent Neural Networks* (RNN) y su extensión, la *Long Short-Term Memory* (LSTM), modelan dependencias a largo plazo en secuencias. Los avances más recientes incorporan arquitecturas de tipo *transformer*, redes generativas (GAN) y *Graph Neural Networks*, ampliando el rango de aplicaciones desde visión y lenguaje hasta química computacional [34].




Figura 10. Comparación entre (a) red superficial y (b) red neuronal profunda [34]

En contextos con ruido o escasez de datos, los métodos de *Ensemble Learning* combinan múltiples modelos débiles para crear un estimador robusto. Los *Random Forests* reducen la varianza al promediar árboles de decisión construidos con *bagging*. Los algoritmos de *Gradient Boosting* (incluidos *XGBoost*, *LightGBM* y *CatBoost*) (Figura 11) corrigen secuencialmente los errores del conjunto, alcanzando resultados de referencia en competiciones de

predicción tabular [35].

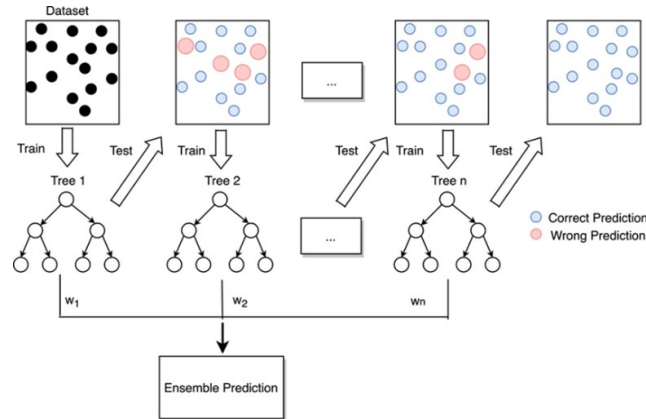


Figura 11. Diagrama de flujo del método de aprendizaje automático de *Gradient Boosting* [36]

6.6. *Machine learning* en la Ingeniería Biomédica

El uso de técnicas de *machine learning* en ingeniería biomédica ha impulsado el análisis automatizado de señales fisiológicas y la toma de decisiones clínicas asistidas. En el área de la imagen médica, por ejemplo, modelos de redes neuronales convolucionales (CNN) han demostrado niveles de precisión comparables a los de especialistas humanos al clasificar distintos tipos de lesiones cutáneas [37]. Este tipo de resultados ilustra el potencial del aprendizaje automático para apoyar procesos diagnósticos en entornos clínicos y reforzar la toma de decisiones (Figura 12), pero su aplicación específica depende del tipo de señal y del contexto experimental de cada estudio.




Figura 12. Matriz de confusión que compara el desempeño de un modelo CNN con dos dermatólogos especializados en la clasificación de lesiones cutáneas, ilustrando un ejemplo del uso de *machine learning* en imagen médica [37]

En radiología torácica, los avances son igualmente notables. El modelo CheXNeXt (Figura 13), ajustado sobre 420 000 radiografías de tórax etiquetadas, detecta catorce patologías (neumonía, nódulos pulmonares, atelectasia, etc.) con un área bajo la curva comparable o

superior a la media de nueve radiólogos generales, al tiempo que reduce de forma sustancial el tiempo de lectura clínica [38]. La automatización de hallazgos comunes libera recursos profesionales y estandariza criterios diagnósticos en hospitales con grandes cargas asistenciales.

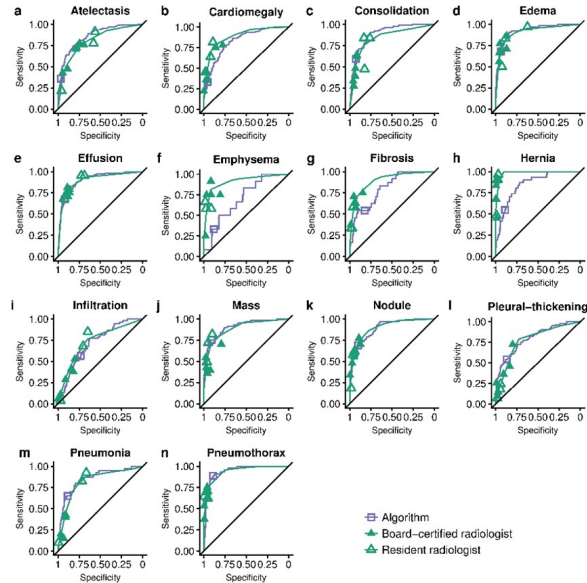


Figura 13. Curvas de comparación entre radiólogos y algoritmos de *machine learning* para detección de patologías pulmonares [38]

El análisis de bioseñales ha sido otro campo transformado por el ML. Redes neuronales recurrentes profundas entrenadas con más de 90 000 horas de electrocardiografía Holter han logrado detectar dieciséis clases de arritmia con una precisión que iguala a cardiólogos certificados, incluso en episodios de fibrilación auricular de corta duración [39]. El ML también impulsa la medicina de precisión al integrar datos genómicos, registros electrónicos de salud y biomarcadores de laboratorio. Modelos de *gradient boosting* y redes profundas son capaces de predecir la aparición de complicaciones en diabetes, identificar pacientes con alto riesgo de sepsis horas antes de los signos clínicos y recomendar intervenciones farmacológicas personalizadas, lo que conduce a una asignación de recursos más eficiente y a mejores resultados clínicos [40].

Las aplicaciones de *machine learning* en la gestión operativa hospitalaria han mostrado que los modelos predictivos, entrenados con historiales de admisión, alta y duración de cirugía, son capaces de anticipar la ocupación de camas y la demanda de quirófanos con varios días de antelación. Esto permite reprogramar agendas y redistribuir recursos, reduciendo tiempos de espera y costes sin afectar los indicadores de calidad asistencial [41]. En investigación farmacológica, técnicas de aprendizaje por refuerzo profundo y redes generativas han acelerado el diseño “*de novo*” de fármacos. En otras palabras, los algoritmos exploran de forma autónoma espacios químicos de gran dimensión, proponen moléculas con alta afinidad prevista y optimizan iterativamente sus propiedades, lo que disminuye ensayos *in-vitro* y acorta el ciclo de descubrimiento [42][43].

6.7. *Machine learning* para EMG

La aplicación de *machine learning* a la electromiografía de superficie (sEMG) ha permitido traducir la actividad eléctrica muscular en información motora útil para control protésico, interfaces hombre-máquina y reconocimiento de gestos complejos. En control protésico de miembro superior, la extracción de la información neural contenida en la sEMG se ha extendido desde esquemas de control proporcional de un solo grado de libertad hasta sistemas multigrado-basados en clasificación continua y regresión de fuerza. Los clasificadores ML convierten los patrones mioeléctricos en comandos simultáneos para varias articulaciones, abriendo vías hacia prótesis con movimientos cercanos a los fisiológicos. Para exoesqueletos de asistencia, modelos híbridos ResNet-BiLSTM estiman en línea la fuerza de interacción del brazo, mejorando la precisión frente a métodos lineales clásicos [44].

En reconocimiento gestual, los algoritmos de ML han alcanzado altos niveles de exactitud con hardware portátil. Un estudio comparativo con datos del brazalete Myo mostró que seis clasificadores supervisados (ANN, SVM, k-NN, NB, DT y RF) pueden identificar siete gestos de mano con precisiones entre 97 % y 100 %; el clasificador Naïve Bayes resultó el más estable en ese conjunto de prueba. Resultados afines se reportan para control de robots, realidad virtual o interfaces para televisión inteligente, confirmando que la sEMG multicanal mejora sensiblemente frente a configuraciones monocanal [7].

Las investigaciones más recientes sobre sEMG se concentran en la traducción automática de lengua de señas, donde las arquitecturas profundas han desplazado a los clasificadores convencionales. Los modelos basados en convoluciones y *long short-term memory* (LSTM) alcanzan precisiones superiores al 95 % gracias a su capacidad para extraer patrones espacio-temporales, especialmente cuando la señal EMG se combina con datos inerciales y se representa en forma de escalogramas [6].

En el control protésico multigrado de libertad, las redes convolucionales entrenadas con la base de datos NinaPro permiten discriminar más de cincuenta agarres y configuraciones de la mano con precisiones cercanas al 90 %, lo que se traduce en señales continuas y estables para prótesis transradiales de última generación [4]. En interfaces hombre-robot orientadas a la asistencia cotidiana, una red recurrente bidireccional entrenada con sEMG de antebrazo estima la fuerza de interacción brazo-exoesqueleto con apenas 50 ms de latencia, incrementando la suavidad del movimiento y la seguridad del usuario [45].

6.8. Lenguaje de señas en Guatemala

La lengua de señas en el ámbito hispanohablante no constituye un sistema único. La Lengua de Signos Española (LSE) cuenta con una gramática propia (orden sujeto-objeto-verbo frecuente, uso de clasificadores espaciales) y un alfabeto manual de 26 configuraciones, codificado y difundido tras su reconocimiento legal en la Ley 27/2007 de España. Dentro de su léxico más habitual se documentan señas básicas de saludo (hola), pronombres personales, verbos de uso diario (comer, beber) y campos semánticos como familia y tiempo. Estudios de frecuencia léxica en corpus videográficos indican que unas 300 señas cubren alrededor del 80 % de la comunicación cotidiana en LSE [1].

En Guatemala, la lengua de señas reconocida es LENSEGUA (Lengua de Señas Guatemalteca), empleada de forma mayoritaria en los centros urbanos de Ciudad de Guatemala y Quetzaltenango, con variantes orientales y occidentales mutuamente comprensibles. Investigaciones sociolingüísticas estiman que cerca del 40 % de la población sorda del país utiliza LENSEGUA como lengua principal de comunicación [2]. Aunque no comparte una genealogía directa con LSE, presenta influencias históricas de la antigua Lengua de Señas Costarricense, así como aportes de sistemas indígenas locales. Mantiene un alfabeto manual propio y un vocabulario que refleja la realidad cultural guatemalteca, por ejemplo, señas específicas para tamal o fiambre [46].

7.1. Colocación de electrodos

Se utilizaron tres canales de EMG, cada uno conformado por un par de electrodos activos de superficie Ag/AgCl (BIOPAC Systems Inc., EE. UU.) y un electrodo de referencia común, formando conjuntos bipolares independientes. Los electrodos fueron colocados en el antebrazo izquierdo sobre los músculos: flexor carpi radialis, palmar largo, pronador cuadrado, extensor digitorum, braquiorradial y flexor digital de los dedos (Figura 14). Dichos músculos fueron seleccionados por su amplia participación en los gestos del lenguaje de señas.




Figura 14. Colocación de electrodos en el antebrazo izquierdo en los músculos: *Flexor Carpi Radialis* (V+₁), *Palmar Largo* (V-₁), *Pronador Cuadrado* (V+₂), *Extensor Digitorum* (V-₂), *Braquiorradial* (V+₃), y *Flexor Digital de los Dedos* (V-₃)

Para las mediciones realizadas con los sensores MyoWare Muscle Sensor 2.0 (Advancer Technologies LLC, EE. UU.), se buscó reproducir la misma disposición anatómica utilizada

con el sistema BIOPAC, de manera que los registros obtenidos fueran comparables. Se emplearon tres sensores independientes, cada uno con un par de electrodos activos integrados y un electrodo de referencia común. Los sensores se colocaron sobre los mismos seis músculos del antebrazo izquierdo: flexor carpi radialis, palmar largo, pronador cuadrado, extensor digitorum, braquiorradial y flexor digital de los dedos, procurando que la ubicación y orientación de los electrodos fuera lo más parecida posible a la configuración empleada con el sistema BIOPAC (Figura 15).




Figura 15. Colocación de los sensores MyoWare Muscle Sensor 2.0 en el antebrazo izquierdo

7.2. Obtención de señales EMG

Las señales electromiográficas se registraron mediante un sistema BIOPAC MP36, con frecuencia de muestreo de 2 kHz, resolución de 16 bits y filtrado analógico integrado de 10–500 Hz. Los registros se realizaron en un laboratorio controlado a 16 °C, tras la limpieza de la piel con alcohol isopropílico. Se capturaron cinco señas del LENSEGUA: Hola, Bien y las configuraciones manuales de las letras C, R y S (Figura 16).




Figura 16. Señas realizadas y sus gestos correspondientes

Para cada gesto se obtuvieron 100 repeticiones consecutivas, intercalando intervalos de reposo de 10 segundos para prevenir fatiga. Previo a la ejecución de cada seña, se registró una línea basal de 30 segundos. Esto quiere decir que 30 segundos antes del inicio de cada gesto, los músculos permanecieron en completo reposo (Figura 17). Este procedimiento generó una sola medición continua que incluía las 100 repeticiones por gesto.

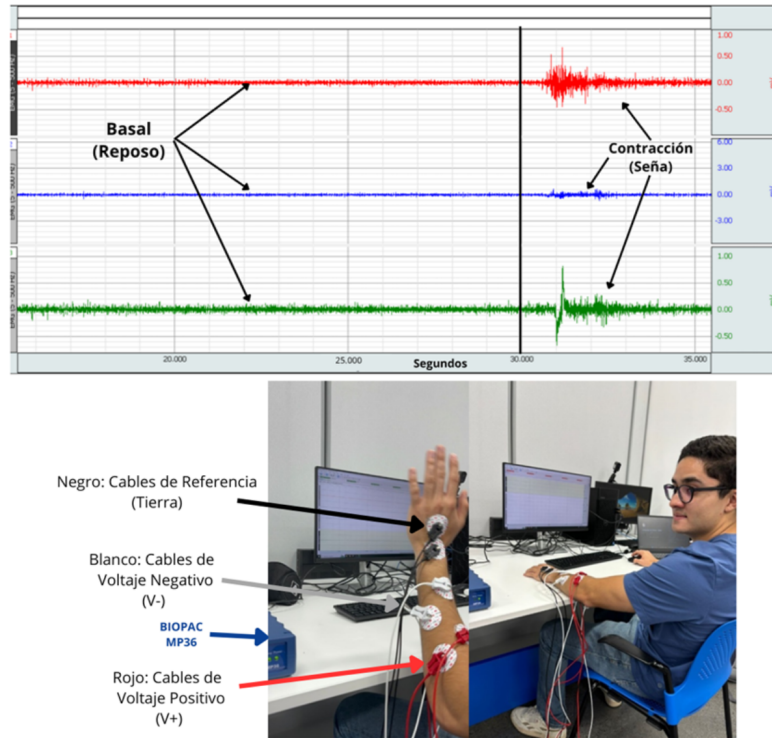


Figura 17. Diagrama del gesto Bien con 30 segundos de medición basal previo a la ejecución del gesto y conexión para la obtención de las señales EMG correspondientes a las señas escogidas del LENSEGUA

En el caso de las mediciones realizadas con los sensores MyoWare Muscle Sensor 2.0, cada canal se conectó a las entradas analógicas del microcontrolador Arduino Uno, asignando el sensor 1 al pin A0, el sensor 2 al A1 y el sensor 3 al A2. Esta configuración permitió registrar de forma simultánea la actividad electromiográfica de los tres canales (Figura 18). Los datos adquiridos por el convertidor analógico-digital (ADC) del Arduino fueron transferidos y almacenados mediante un script en Python, el cual permitió la lectura en tiempo real de los valores de los sensores y la generación automática de archivos en formato .CSV. En este caso, no se realizaron los intervalos de 10 segundos de reposo entre repeticiones ni los 30 segundos de reposo inicial, ya que el programa en Python permitió grabar cada fragmento de señal de manera individual, controlando el inicio y final de cada registro sin necesidad de pausas intermedias. De esta manera, se obtuvo un set de datos independiente de señales EMG crudas correspondientes al sistema MyoWare.




Figura 18. Conexión de sensores MyoWare Muscle Sensor 2.0 con Arduino UNO

7.3. Procesamiento de las señales EMG

Los archivos obtenidos en formato .MAT y .CSV fueron exportados a MATLAB R2020b (MathWorks, MA, EE. UU.). A cada registro de los datos obtenidos con BIOPAC, se aplicó rectificación absoluta y cálculo de la envolvente RMS mediante ventanas móviles. Se realizó la rectificación absoluta, un proceso mediante el cual todos los valores negativos de la señal EMG filtrada se transforman en positivos. Matemáticamente, esto equivale a tomar el valor absoluto de cada muestra de la señal, de modo que la amplitud siempre represente la magnitud de la actividad eléctrica, sin distinguir la dirección del potencial. Con ello se preserva la información sobre la intensidad de los potenciales musculares y se elimina la componente alternante negativa.

A continuación, se calculó la envolvente RMS (*Root Mean Square*). Este procedimiento consiste en elevar al cuadrado los valores rectificados dentro de cada ventana, obtener su promedio y finalmente extraer la raíz cuadrada del resultado. El cálculo RMS proporciona una medida continua del nivel de activación muscular a lo largo del tiempo, al suavizar las fluctuaciones rápidas de la señal cruda (Figura 19).

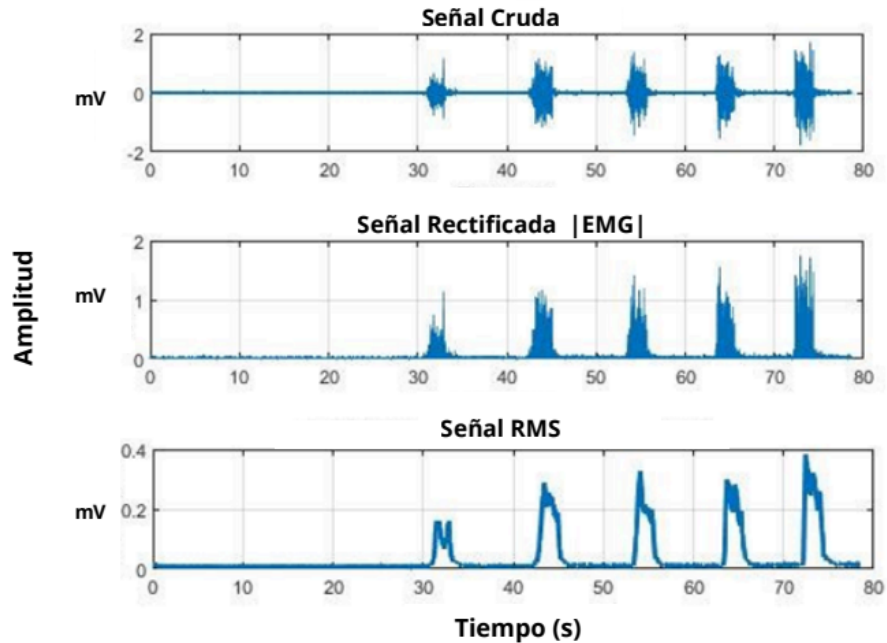


Figura 19. Rectificación absoluta de la señal EMG y envolvente RMS de la señal rectificada

Asimismo, se realizó un procesamiento adicional para las señales EMG en crudo, es decir, sin aplicar rectificación. En estas señales únicamente se implementó un filtrado digital para la reducción de ruido, manteniendo la morfología original de los potenciales de acción. Este filtrado consistió en la aplicación de un filtro pasa-banda Butterworth de cuarto orden con frecuencias de corte de 20 Hz y 450 Hz, diseñado mediante la función de MATLAB `but-
 ter(4,[20 450]/(fs/2),'bandpass')` y aplicado con `filtfilt(b,a,x)` para eliminar artefactos de baja frecuencia y ruido de alta frecuencia, sin introducir desfase. En este contexto, `b` y `a` representan los coeficientes del filtro digital (numerador y denominador del modelo recursivo, respectivamente), mientras que `x` corresponde a la señal EMG de entrada sobre la cual se aplica el filtrado. Este rango de frecuencias, del filtro Butterworth, es comúnmente empleado en electromiografía de superficie para eliminar artefactos de baja frecuencia (movimiento y línea base) y atenuar interferencias de alta frecuencia (ruido eléctrico) (Figura 20).

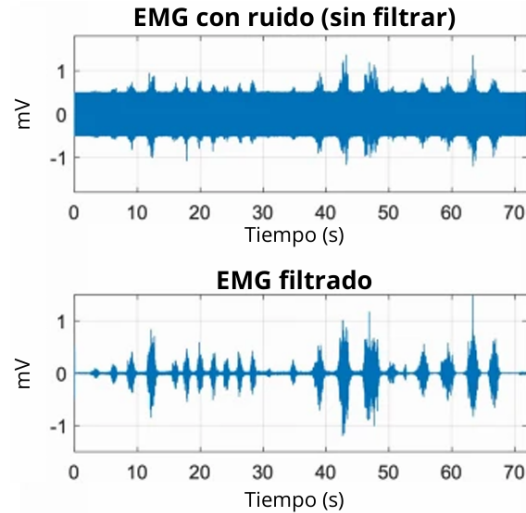


Figura 20. Procesamiento de la señal EMG en crudo mediante filtro pasabanda Butterworth de cuarto orden

Posteriormente, los resultados fueron segmentados en 100 registros por seña, normalizados y almacenados en archivos .mat. De esta manera, se obtuvieron dos sets de datos independientes de 500 muestras en total con BIOPAC MP36, uno de muestras RMS y otro de crudas, para su análisis mediante algoritmos de aprendizaje automático.

En el caso del conjunto de datos obtenido con los sensores MyoWare Muscle Sensor 2.0, las señales electromiográficas adquiridas fueron siempre positivas debido a que el conversor analógico–digital (ADC) del Arduino UNO sólo registra valores dentro del rango de 0–5 V. Para permitir la comparación directa con las señales crudas registradas mediante el sistema BIOPAC, que son bipolares y están centradas alrededor de 0 mV, las señales de MyoWare fueron procesadas digitalmente para reubicarlas alrededor de 0 mV mediante una operación de centrado. Este ajuste permitió representar las variaciones electromiográficas con una referencia común y mantener la coherencia entre ambos sistemas de adquisición.

7.4. Entrenamiento de modelos de aprendizaje automático

El *dataset* balanceado se dividió mediante partición estratificada, reservando el 20 % de las muestras obtenidas como conjunto de prueba independiente y utilizando el 80 % restante para entrenamiento con validación cruzada K-fold de cinco pliegues. En este procedimiento, el conjunto de entrenamiento se subdividió en cinco subconjuntos de igual tamaño. En cada iteración, cuatro pliegues fueron empleados para entrenar y el pliegue restante para validar, repitiéndose el proceso hasta que cada subconjunto fue utilizado una vez. El desempeño de cada modelo se reportó como el promedio y la desviación estándar de las cinco iteraciones, lo que permitió obtener una estimación más robusta de su capacidad de generalización.

Este procedimiento se aplicó tanto al dataset de señales rectificadas como al dataset de señales en crudo (Biopac y Myoware). Para las señales RMS, se construyó una matriz de características que incluyó *slope sign changes* (SSC), media, varianza y *waveform length*

(WL) (Cuadro 1) (Figura 21).

Cuadro 1. Parámetros y descripción de características de la señal EMG en RMS

Parámetro	Descripción
<i>Slope Sign Changes (SSC)</i>	Cuenta el número de cambios en la pendiente de la señal.
<i>Waveform Length (WL)</i>	Suma de las diferencias absolutas entre muestras consecutivas.
Media	Promedio de la amplitud de la señal.
Varianza	Medida de la dispersión de la señal respecto a su media.




Figura 21. Ejemplo ilustrativo de una señal EMG donde se muestran las características utilizadas como parámetros de entrada: *slope sign changes* (SSC), *waveform length* (WL), media y varianza

Para las señales en crudo, la tabla de características se conformó con *zero crossings* (ZC), frecuencia media, frecuencia mediana, *root mean square* (RMS) y *mean absolute value* (MAV) (Cuadro 2) (Figura 22).

Cuadro 2. Parámetros y descripción de características en el dominio de la frecuencia para set de datos en crudo

Parámetro	Descripción
<i>Zero crossings (ZC)</i>	Número de veces que la señal cambia de signo.
<i>Frecuencia media (MF)</i>	Promedio ponderado del espectro de potencia.
<i>Frecuencia mediana (MDF)</i>	Frecuencia que divide el espectro de potencia en dos áreas iguales.
<i>Root mean square (RMS)</i>	Valor cuadrático medio de la señal.
<i>Mean absolute value (MAV)</i>	Promedio de los valores absolutos.




Figura 22. Ilustración de las características del dominio de la frecuencia empleadas como parámetros de entrada: *zero crossings* (ZC), *frecuencia media* (MF), *frecuencia mediana* (MDF), *root mean square* (RMS) y *mean absolute value* (MAV)

El entrenamiento se realizó en MATLAB R2020b mediante la aplicación *Classification Learner*. Las características se importaron en formato .mat como tablas, definiendo la clase de cada señal como variable de respuesta. La validación se configuró con partición estratificada y validación cruzada K-fold de cinco pliegues. Luego se añadieron los clasificadores de interés (SVM, KNN, discriminantes, etc.) (Cuadro 3) y se evaluaron según exactitud promedio y matrices de confusión. El modelo con mayor exactitud y menor variabilidad se validó en el conjunto de prueba reservado y se exportó al *Workspace* como función para su posterior implementación.

Cuadro 3. Algoritmos de entrenamiento de *machine learning* de la aplicación *Classification Learner*

Modelo	Función
<i>Fine Tree</i>	Divide el espacio de datos en regiones pequeñas mediante divisiones sucesivas que maximizan la ganancia de información; puede sobreajustar.
<i>Medium Tree</i>	Realiza divisiones intermedias; busca equilibrio entre precisión y generalización.
<i>Coarse Tree</i>	Usa pocas divisiones; genera fronteras simples y generaliza bien, pero con menor detalle.
<i>Linear discriminant</i>	Calcula fronteras lineales suponiendo igual covarianza entre clases.
<i>Quadratic Discriminant</i>	Permite covarianzas distintas por clase; genera fronteras cuadráticas más flexibles.
<i>Gaussian Naive Bayes</i>	Aplica el teorema de Bayes asumiendo independencia entre variables y distribución normal por clase.
<i>Kernel Naive Bayes</i>	Estima probabilidades con funciones kernel, sin asumir distribución gaussiana.
<i>Linear SVM</i>	Encuentra el hiperplano que maximiza el margen entre clases linealmente separables.
<i>Quadratic SVM</i>	Usa un kernel polinómico de grado 2 para modelar separaciones no lineales moderadas.
<i>Fine Gaussian SVM</i>	Kernel gaussiano con ancho pequeño; genera límites precisos pero sensibles al ruido.
<i>Medium Gaussian SVM</i>	Kernel gaussiano de varianza media; balance entre complejidad y generalización.
<i>Coarse Gaussian SVM</i>	Kernel gaussiano ancho; produce fronteras suaves y robustas al ruido.
<i>Fine KNN</i>	Clasifica según pocos vecinos; alta resolución pero sensible al ruido.
<i>Medium KNN</i>	Considera número medio de vecinos; buen equilibrio entre precisión y estabilidad.
<i>Coarse KNN</i>	Usa muchos vecinos; fronteras suaves y mayor robustez.
<i>Cosine KNN</i>	Usa la similitud del coseno como métrica en lugar de la distancia euclidiana.
<i>Cubic KNN</i>	Usa distancia cúbica, acentuando diferencias grandes entre muestras.
<i>Weighted KNN</i>	Asigna más peso a los vecinos cercanos al clasificar.
<i>Boosted Trees</i>	Combina árboles secuenciales donde cada uno corrige errores del anterior (boosting).
<i>Bagged Trees</i>	Promedia varios árboles entrenados sobre subconjuntos aleatorios (bagging).
<i>Subspace Discriminant</i>	Entrena discriminantes en subespacios aleatorios y combina sus resultados.
<i>Subspace KNN</i>	Combina múltiples clasificadores KNN entrenados en diferentes subconjuntos de variables.
<i>RUSBoosted Trees</i>	Aplica boosting con submuestreo aleatorio para equilibrar clases desbalanceadas.

7.5. Implementación y validación del modelo seleccionado

El modelo exportado fue probado con un dataset independiente compuesto por señales EMG correspondientes a las mismas señas utilizadas durante el entrenamiento. Dicho set de datos permitió evaluar la capacidad del clasificador para generalizar a nuevas adquisiciones bajo las mismas condiciones experimentales. La validación consistió en aplicar el modelo entrenado a estas señales no vistas previamente y comparar las predicciones con las etiquetas reales (Figura 23), generando métricas de desempeño como exactitud global y matriz de confusión.

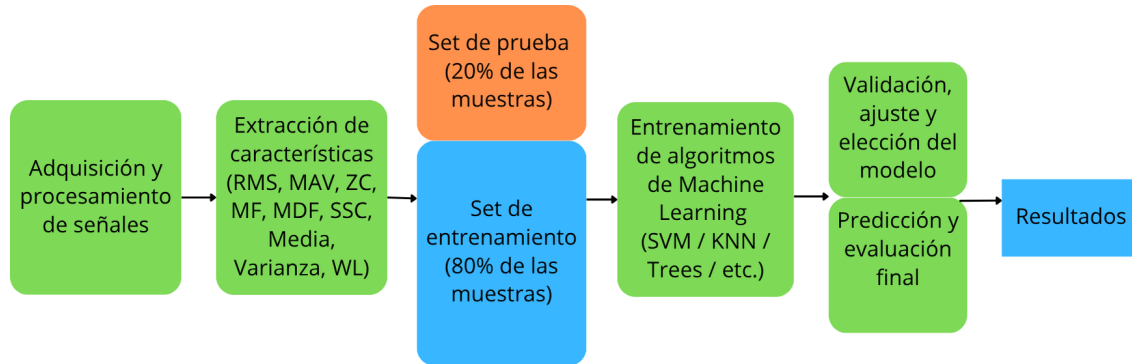


Figura 23. Secuencia de entrenamiento y validación de modelos de Machine Learning

8.1. Set de datos de señales EMG crudas/RMS - BIOPAC

Las señales EMG en crudo (Figura 24) permiten observar la morfología original de los potenciales eléctricos generados por la contracción muscular antes de cualquier procesamiento digital. El gesto “Bien” muestra una mayor amplitud y densidad de potenciales en los canales 1 y 2. Estos canales tienen una secuencia de activaciones repetidas, logrando una superposición densa de repeticiones que indican un esfuerzo más prolongado; dichas activaciones se encuentran entre -1 mV y 1 mV aproximadamente. En el caso del canal 3, la amplitud es menor, ya que se ubica entre -0.5 mV y 1 mV. Las señales del gesto “C” presentan una activación breve con amplitudes relativamente bajas, entre el intervalo de -1 mV y 1 mV, y con una forma de onda estable entre canales. En el gesto “Hola”, las señales presentan mayor densidad y amplitud en los tres canales, con actividad más continua a lo largo del registro; la amplitud de esta señal se encuentra entre -0.5 mV y 0.5 mV, sin embargo, su densidad es concentrada. Para las señales de “R”, se observa un patrón de alta amplitud con un inicio marcado y una disminución progresiva hacia el final del registro. Finalmente, en la seña “S” las señales presentan una activación breve y concentrada en el tiempo, con picos de amplitud definidos y menor densidad en los canales 2 y 3.

Las señales EMG RMS (Figura 24) muestran un comportamiento más suave, con transiciones progresivas y coherentes entre canales. El gesto “Bien” muestra una activación más prolongada en el tiempo, con amplitudes mayores principalmente en el canal 1 debido a valores atípicos; tiene una superposición densa y mayor similitud de repeticiones en los canales 2 y 3. Las señales de “C”, evidencian una activación breve y de baja amplitud, con una forma de onda estable y similar entre los tres canales, lo que sugiere una contracción corta y localizada. El gesto “Hola” presenta la mayor densidad entre los tres canales, con una actividad continua durante casi todo el registro, lo cual sugiere la participación simultánea de varios músculos y una contracción más amplia tanto en duración como en intensidad; además, muestra una gran similitud entre todas las señales en sus respectivos canales, demostrando una reproducibilidad alta. Las señales del gesto “R” muestran un patrón característico con un

pico de amplitud pronunciado al inicio y una disminución progresiva hacia el final, reflejando una contracción rápida seguida de una relajación gradual. Las señales correspondientes al gesto “S” presentan una activación breve y concentrada en el tiempo, con picos definidos y menor densidad en los canales 2 y 3, lo que indica una contracción puntual y de menor extensión muscular.

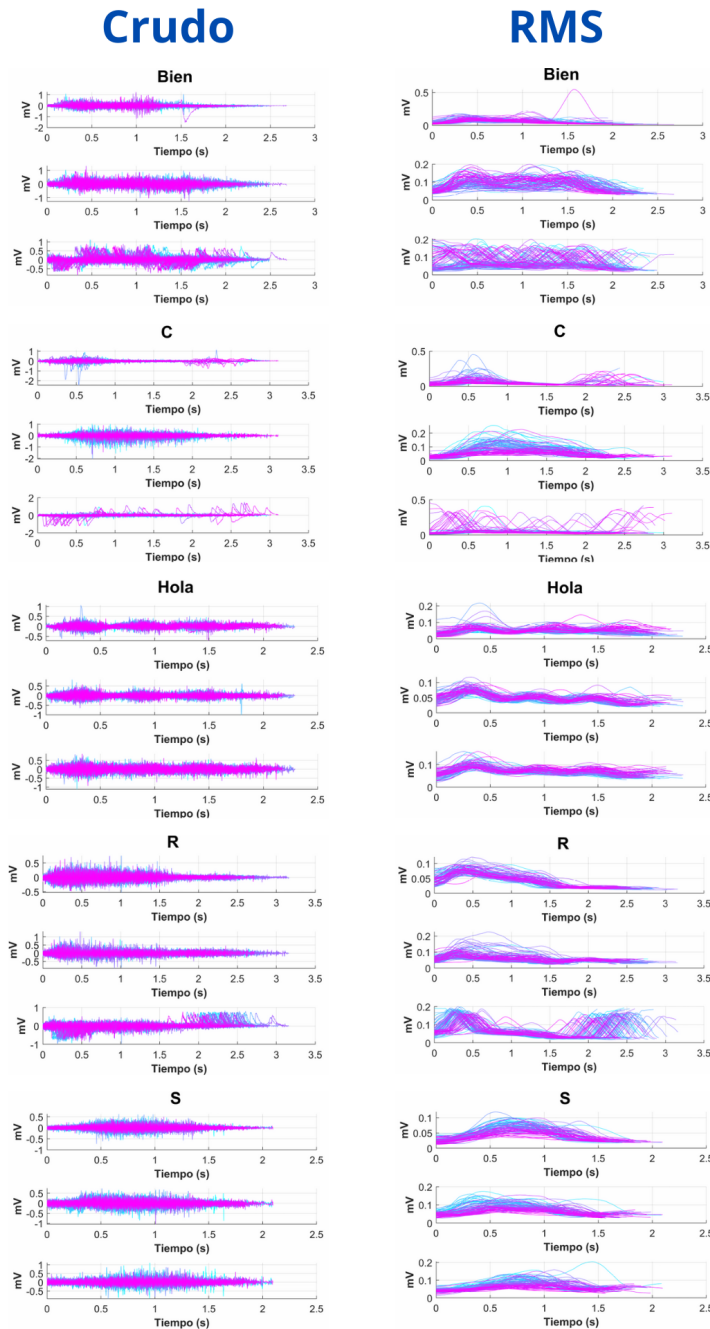


Figura 24. Señales en crudo (columna 1) y RMS (columna 2) superpuestas obtenidas con BIOPAC MP36. El número de muestras por seña es de 100. En forma descendente se encuentra “Bien”, “C”, “Hola”, “R” y “S”

8.2. Set de datos de señales EMG crudas – MyoWare muscle sensor 2.0

Las señales EMG en crudo obtenidas con los sensores MyoWare Muscle Sensor 2.0 (Figura 25) permiten notar las diferencias en los potenciales eléctricos generados por la contracción muscular correspondientes a cada seña. El gesto “Bien” presenta una activación de mayor duración y amplitud, especialmente en los canales 2 y 3, donde se observan repeticiones superpuestas que indican un esfuerzo muscular más sostenido y una mayor participación de los músculos. En las señales del gesto “C”, se muestra una activación breve y de baja amplitud, entre -270 mV y 270 mV, con una forma de onda estable y homogénea entre los tres canales, lo que sugiere una contracción corta y localizada. El gesto “Hola” exhibe una mayor densidad de actividad y amplitudes más elevadas en comparación con los demás gestos, con registros prolongados y una activación simultánea, especialmente en el canal 1 y 2. Sin embargo, el canal 3 muestra una actividad muscular diminuta. Las señales del gesto “R” se caracterizan por picos de alta amplitud al inicio del registro, seguidos de una disminución progresiva hacia el final, lo que indica una contracción rápida inicial y una relajación gradual. Cabe mencionar que tiene muchos datos atípicos en sus amplitudes. Finalmente, el gesto “S” presenta activaciones de corta duración y baja densidad, con picos definidos y concentrados en los primeros segundos del registro, mostrando menor participación en el canal 3 (Figura 25).

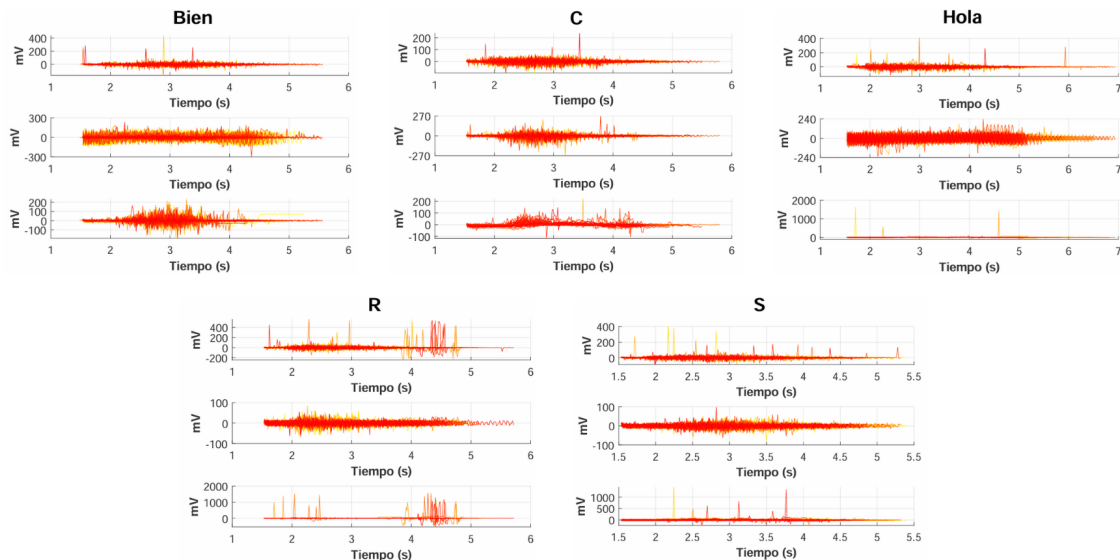


Figura 25. Señales EMG crudas superpuestas registradas con tres sensores Myoware Muscle Sensor 2.0. El número de muestras por seña es de 100. Primera fila, de izquierda a derecha: “Bien”, “C”, “Hola”. Segunda fila, de izquierda a derecha: “R” y “S”

8.3. Entrenamiento de modelos de *machine learning* con set de datos en crudo de BIOPAC

En el set de 100 muestras por seña, los modelos *Quadratic SVM*, *Cubic SVM* y *Linear Discriminant* alcanzaron un desempeño prácticamente idéntico, con una precisión de 99.4 %, evidenciando una excelente capacidad de generalización y consistencia en la clasificación de las señales EMG sin procesar. En contraste, los modelos *Boosted Trees* y *RUSBoosted Trees* obtuvieron únicamente 20 % de precisión (Figura 26). Al reducir el tamaño del conjunto a 50 muestras por seña, el modelo *Linear Discriminant* mantuvo su comportamiento robusto, alcanzando una precisión de 99.6 %, mientras que los modelos basados en árboles de decisión, *Boosted Trees* y *RUSBoosted Trees*, continuaron mostrando un rendimiento limitado de 20 % (Figura 26). Finalmente, en el set de 25 muestras por seña, los algoritmos *Linear Discriminant*, *Quadratic SVM*, *Cubic SVM*, *Medium Gaussian SVM* y *Fine KNN* lograron una precisión perfecta del 100 %, demostrando que la reducción de datos no afectó negativamente el desempeño de los clasificadores más estables. Por otro lado, los modelos *Boosted Trees* y *RUSBoosted Trees* repitieron su bajo desempeño de 20 % de precisión, reafirmando su limitada adaptación a este tipo de datos (Figura 26).

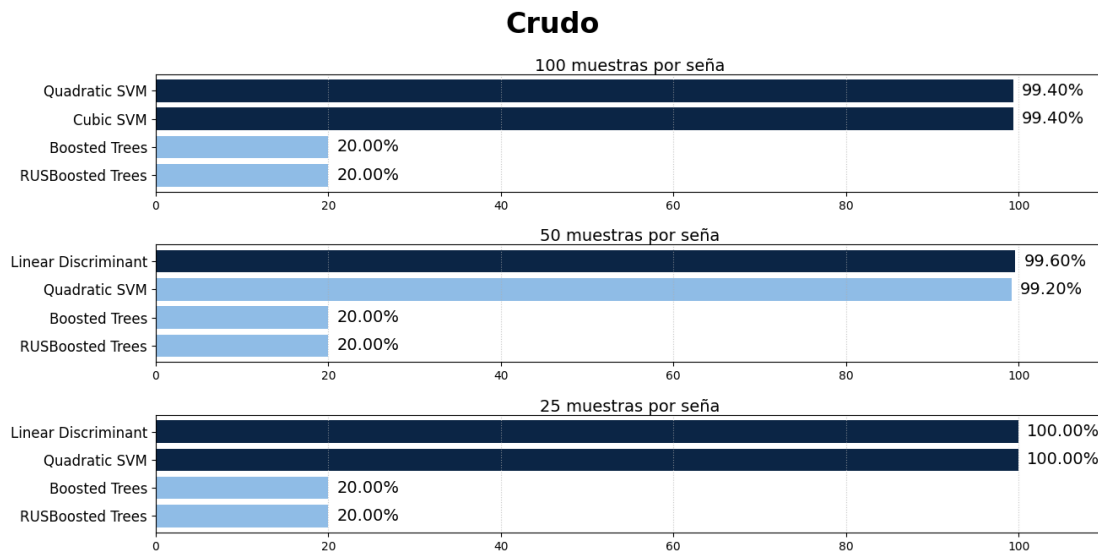


Figura 26. Resultados de precisión de los modelos de *machine learning* entrenados con el conjunto de datos crudo de BIOPAC

Con 100 muestras por seña, el modelo *Quadratic SVM* mostró una precisión similar (99.4 %), presentando únicamente tres errores: uno correspondiente al gesto “R” clasificado erróneamente como “Bien”, otro del gesto “Hola” asignado a “S”, y el último del gesto “Bien” clasificado como “R”. Por su parte, el modelo *Cubic SVM* alcanzó también 99.4 % de precisión, con exactamente las mismas confusiones que el modelo *Quadratic SVM* (figura 27). En el conjunto de 50 muestras por seña, el modelo *Linear Discriminant* mantuvo un desempeño sobresaliente, alcanzando una precisión del 99.6 %. Todas las clases fueron correctamente identificadas, con excepción de una señal del gesto “R” que fue clasificada erróneamente como “Bien”. Por su parte, en el conjunto de 25 muestras por seña, todos los modelos evaluados (*Linear Discriminant*, *Quadratic SVM*, *Cubic SVM*, *Medium Gaussian SVM* y *Fine KNN*)

lograron una precisión perfecta del 100 %, sin presentar errores de clasificación en ninguna de las clases (figura 27).

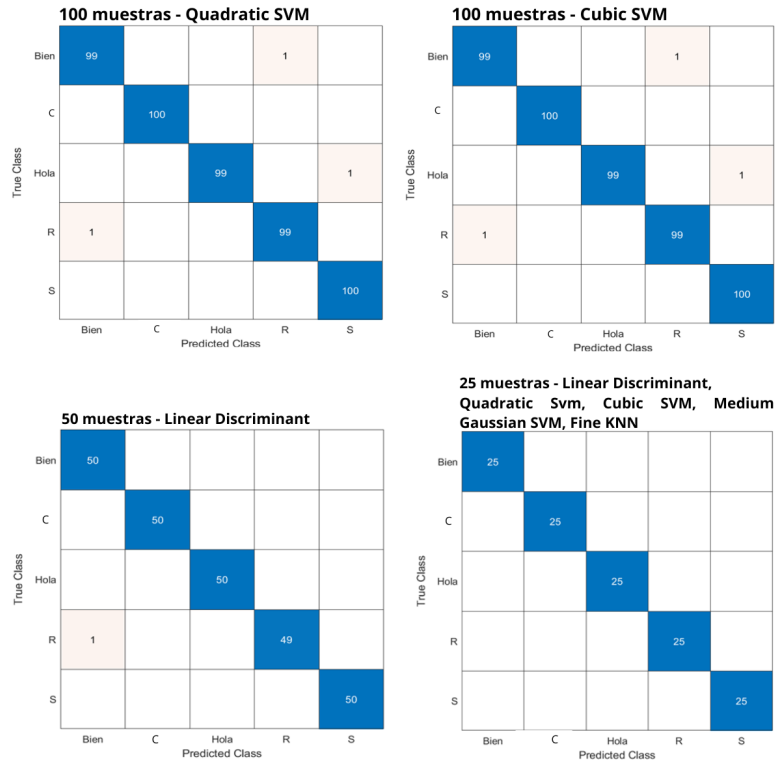


Figura 27. Matrices de confusión (MC) de los modelos con mayor rendimiento para el set de datos en crudo con 100 muestras por seña, 50 muestras por seña y 25 muestras por seña

8.4. Entrenamiento de modelos de *machine learning* con set de datos RMS de BIOPAC

En el set de 100 muestras por seña, los modelos *Quadratic SVM* y *Quadratic Discriminant* alcanzaron las mayores precisiones, con 97.4 % y 97.2 %, respectivamente. En contraste, los modelos *Coarse Tree* y *Subspace KNN* mostraron un rendimiento moderado, con valores de precisión entre 74.8 % y 70.4 % (Figura 28). Al reducir el tamaño del conjunto a 50 muestras por seña, el modelo *Linear Discriminant* obtuvo la mayor precisión, con 98 %, seguido muy de cerca por *Subspace Discriminant* con 97.6 %. Por el contrario, los modelos *Boosted Trees* y *RUSBoosted Trees* disminuyeron considerablemente su desempeño, alcanzando precisiones de 20 %, respectivamente (Figura 28). Finalmente, en el set de 25 muestras por seña, los modelos *Cubic SVM* y *Quadratic SVM* mantuvieron un rendimiento sobresaliente, con una precisión de 98.4 %. En contraste, los modelos *Coarse KNN*, *Boosted Trees* y *RUSBoosted Trees* repitieron un bajo desempeño de 20 % (Figura 28).




Figura 28. Resultados de precisión de los modelos de *machine learning* entrenados con el set de datos RMS de BIOPAC

En la matriz de confusión de 100 muestras por seña, correspondiente al modelo *Quadratic SVM*, se obtuvo un rendimiento general del 97.4 % (Figura 29). El gesto “Bien” presentó cuatro confusiones con “R” y una con “Hola”. El gesto “C” mostró también una confusión con “R” y una con “S”. Por su parte, el gesto “R” registró cinco clasificaciones erróneas (tres como “Bien” y dos como “Hola”), mientras que el gesto “S” mostró una confusión aislada con “Bien”.

En el conjunto de 50 muestras por seña, correspondiente al modelo *Linear Discriminant*, se alcanzó una precisión global del 98 % (Figura 29). La matriz de confusión evidencia un elevado nivel de acierto en todas las clases, con únicamente cinco confusiones menores. El gesto “Bien” presentó una confusión con “Hola” y dos con “R”. El gesto “C” registró una confusión con “R”. Finalmente, el gesto “R” tuvo una sola confusión con “Bien”.

Con el set de datos de 25 muestras por seña, los modelos *Cubic SVM* y *Quadratic SVM* (Figura 29) mantuvieron un rendimiento sobresaliente, alcanzando una precisión general del 98.4 % La matriz de confusión correspondiente al *Cubic SVM*, se observan únicamente dos confusiones leves: una señal de “Bien” fue clasificada como “C”, y otra como “R”. De forma similar, en la matriz de confusión correspondiente al modelo *Quadratic SVM*, se identifican también dos errores de clasificación: una señal de “R” clasificada como “Bien”, y una de “Bien” clasificada como “R”.

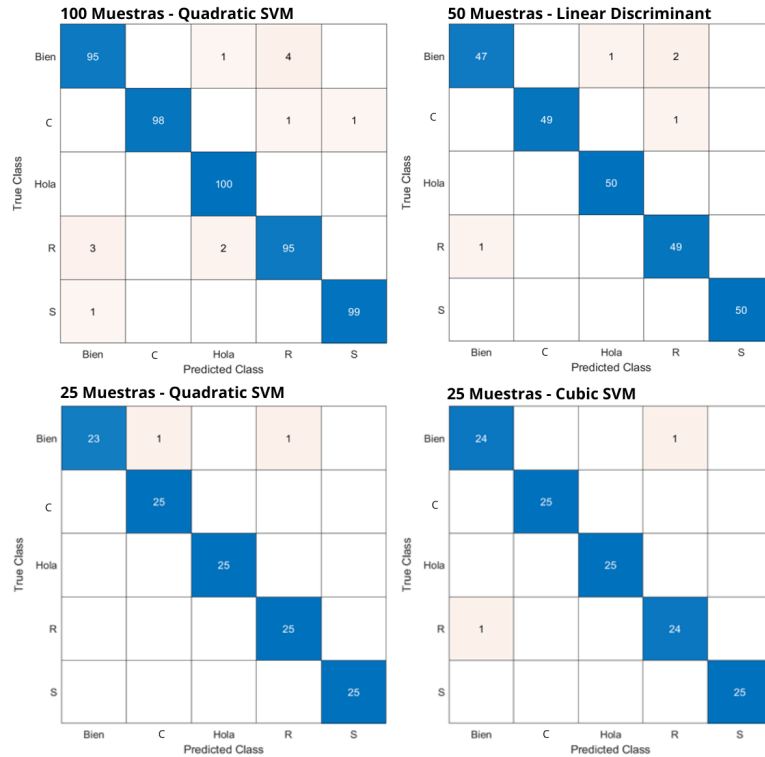


Figura 29. Matrices de confusión (MC) de los modelos con mayor rendimiento para el set de datos RMS con 100 muestras por seña, 50 muestras por seña y 25 muestras por seña

8.5. Entrenamiento de modelos de *machine learning* con el set de datos en crudo de MyoWare Muscle Sensor 2.0

Los modelos *Medium Gaussian SVM* y *Bagged Trees* destacaron por su desempeño superior, alcanzando precisiones de 91.8% y 91.2%, respectivamente, al clasificar las señales EMG crudas obtenidas con sensores MyoWare con un set de datos de 100 muestras por seña. En contraste, los modelos *Fine Gaussian SVM* y *Coarse KNN* obtuvieron un rendimiento moderado, con valores de 63.4% a 66.4% (Figura 30). Con 50 muestras por seña, los algoritmos *Cubic SVM* y *Linear SVM* lograron los mejores resultados, alcanzando 92.8% y 92.4% de precisión, respectivamente. En cambio, los modelos *Coarse KNN*, *RUSBoosted Trees* y *Boosted Trees* disminuyeron su rendimiento a 48.4% (Figura 30). Finalmente, con 25 muestras por seña, los modelos *Linear Discriminant* y *Linear SVM* conservaron un rendimiento notable, con precisiones de 89.6% y 87.2%, respectivamente. En cambio, los algoritmos *RUSBoosted Trees*, *Boosted Trees* y *Coarse KNN* repitieron un rendimiento limitado de 20 (Figura 30).

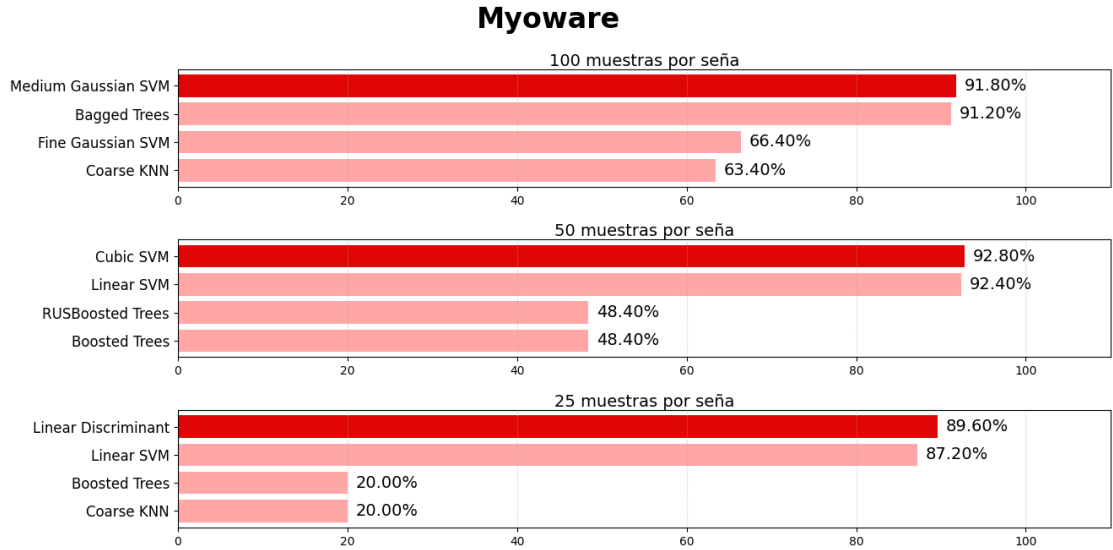


Figura 30. Resultados de precisión de los modelos de *machine learning* entrenados con el set de datos en crudo de Myoware

En el modelo de 100 muestras por seña, correspondiente al *Medium Gaussian SVM*, se observa un buen nivel de acierto global (91.8%), con las confusiones más relevantes concentradas en los gestos “Bien” y “”. En particular, tres señales de “Bien” fueron clasificadas erróneamente como “R”, y tres como “C”. El gesto “S”, por su parte, presentó 13 clasificaciones incorrectas como “R” (Figura 31). El modelo *Cubic SVM* corresponde a un set de datos de 50 muestras por seña, donde la precisión general fue de 92.8%. Se registraron errores mínimos, como una señal de “Hola” clasificada como “Bien”, cinco de “R” como “S”, y seis de “S” identificadas como “R”. Finalmente, en el modelo de 25 muestras por seña, correspondiente al *Linear Discriminant*, la precisión alcanzó 89.6%; las confusiones fueron: cuatro señales de “Bien” fueron clasificadas como “R”, mientras que el gesto “Hola” mostró dispersión leve, con una señal mal clasificada en cada una de las otras clases (Figura 31).




Figura 31. Resultados de precisión de los modelos de *machine learning* entrenados con el set de datos en crudo de Myoware

8.6. Precisión según cantidad de canales usados

Con tres canales, los modelos *Quadratic SVM* y *Cubic SVM* alcanzaron el desempeño más alto, ambos con 99.4% de precisión. En contraste, los modelos basados en árboles, *Boosted Trees* y *RUSBoosted Trees*, obtuvieron únicamente 20% de precisión. Al limitar la clasificación a dos canales, el rendimiento general se mantuvo elevado, aunque con una ligera disminución. Los modelos *Quadratic Discriminant* y *Linear SVM* lograron precisiones de 98.4% y 97.6%, respectivamente, mientras que los algoritmos *Boosted Trees* y *RUSBoosted Trees* mejoraron su desempeño hasta 78%. Finalmente, al utilizar un solo canal, los modelos *Quadratic SVM* y *Cubic SVM* conservaron una precisión alta, de 94.4% y 93%, respectivamente. En esta configuración, los modelos *Coarse Tree* y *Subspace KNN* descendieron a 79.8% y 72% (Figura 32).




Figura 32. Precisión de los modelos de *machine learning* entrenados con el set de datos de 100 muestras por señal en señales EMG crudas, evaluados según la cantidad de canales de adquisición utilizados

Con tres canales, los modelos *Quadratic SVM* y *Quadratic Discriminant* obtuvieron los mejores resultados, con precisiones de 97.4% y 97.2%, respectivamente. En cambio, los modelos *Coarse Tree* y *Subspace KNN* mostraron un desempeño moderado, con 74.8% y 70.4%. Al emplear únicamente dos canales, el rendimiento se mantuvo elevado, con el modelo *Medium Gaussian SVM* alcanzando 94.8% de precisión, seguido muy de cerca por *Quadratic Discriminant* con 94.6%. Los modelos *Coarse Tree* y *Subspace KNN*, sin embargo, presentaron caídas notables en su rendimiento (69.6% y 60%, respectivamente). Por último, con un solo canal, los modelos *Quadratic SVM* y *Cubic SVM* mantuvieron precisiones aceptables de 86.6% y 86.4%, respectivamente, mostrando una buena estabilidad incluso con información limitada. En contraste, *Coarse Tree* y *Subspace KNN* descendieron significativamente a 51.8% y 43.4% (Figura 32).

RMS - 100 muestras por seña




Figura 33. Precisión de los modelos de *machine learning* entrenados con el set de datos RMS con 100 muestras por seña, evaluados según la cantidad de canales de adquisición utilizados

Con tres canales, los modelos *Medium Gaussian SVM* y *Bagged Trees* alcanzaron los valores más altos de precisión, con 91.8% y 91.2%, respectivamente. En contraste, los algoritmos *Fine Gaussian SVM* y *Coarse KNN* mostraron un rendimiento moderado, con precisiones de 66.4% y 63.4%. Al reducir la información a dos canales, los modelos *Quadratic SVM* y *Quadratic Discriminant* mantuvieron un desempeño sólido, con 80% y 79.6% de precisión, respectivamente. Sin embargo, los clasificadores *Fine KNN* y *Fine Gaussian SVM* descendieron a 65.4% y 56.6%. Con un solo canal, la precisión global disminuyó significativamente, alcanzando 46% para el modelo *Linear SVM* y 45.8% para *Linear Discriminant*, mientras que los algoritmos *Quadratic Discriminant* y *Subspace KNN* redujeron su rendimiento a 38.4% y 28.8%, respectivamente (Figura 34).




Figura 34. Precisión de los modelos de *machine learning* entrenados con el set de datos MyoWare crudo (100 muestras por seña), evaluados según la cantidad de canales de adquisición utilizados

8.7. Etapa de validación de modelos

Se muestran los resultados obtenidos al validar el modelo *Cubic SVM* entrenado con 100 muestras crudas por seña (BIOPAC) utilizando un nuevo conjunto de datos obtenido con el sistema BIOPAC MP36. De las cinco señas evaluadas, únicamente el gesto “Hola” fue correctamente identificado en la totalidad de sus repeticiones (5/5 aciertos, 0% de error), mientras que las señas “Bien”, “C”, “R” y “S” presentaron una tasa de error del 100%, sin clasificaciones correctas. En los casos erróneos, se observó una tendencia de confusión hacia las clases “Hola” y “S”: la seña “Bien” fue clasificada como “S” en una ocasión y como “Hola” en cuatro, mientras que “C” fue identificada como “S” en cuatro casos y como “Hola” en uno. De igual manera, las señas “R” y “S” fueron clasificadas erróneamente como “Hola” en las cinco repeticiones evaluadas. En conjunto, los resultados reflejan que el modelo logró reconocer correctamente solo una de las cinco clases, con una marcada tendencia a predecir las señas “Hola” y “S” en la mayoría de los casos (Figura 35).

Matriz de confusión — Cubic SVM (100 muestras crudas por seña)




Figura 35. Validación de *Cubic SVM* entrenado con 100 muestras crudas por seña (BIOPAC MP36) al ser probado con un nuevo set de datos

El modelo *Linear Discriminant* entrenado con 100 muestras crudas por seña (BIOPAC) fue probado con un nuevo conjunto de datos obtenido con el sistema BIOPAC MP36. Los resultados evidencian un comportamiento polarizado, ya que solo la seña “S” fue correctamente identificada en todas sus repeticiones (5/5 aciertos, 0% de error), mientras que las señas “Bien”, “C”, “Hola” y “R” registraron una tasa de error del 100%, sin clasificaciones correctas. En todos los casos erróneos, las predicciones se concentraron exclusivamente en la clase “S” (Figura 36).

Matriz de confusión — Linear Discriminant (100 muestras crudas por seña)




Figura 36. Validación de *Linear Discriminant* entrenado con 100 muestras crudas por seña (BIOPAC MP36) al ser probado con un nuevo set de datos

El modelo *Quadratic SVM* fue entrenado con 100 muestras crudas por seña (BIOPAC) y validado con un nuevo set del BIOPAC MP36. El modelo identificó correctamente solo la seña “S” (5/5 aciertos, 0% de error), mientras que “Bien”, “Hola” y “R” fueron clasificadas erróneamente como “S” en todos los casos (100% de error). La seña “C” mostró un desempeño parcial, con tres aciertos y dos errores (40% de error) (Figura 37).

Matriz de confusión — Quadratic SVM (100 muestras crudas por seña)




Figura 37. Validación de Quadratic SVM entrenado con 100 muestras crudas por seña (BIOPAC MP36) al ser probado con un nuevo set de datos

El modelo *Quadratic SVM* entrenado con 100 muestras RMS por seña (Biopac) y validado con un nuevo set del BIOPAC MP36. Las señas “Hola” y “S” alcanzaron el mejor desempeño, con 80% de aciertos (1 error cada una), mientras que “C” obtuvo un resultado intermedio con 20% de precisión y tendencia a ser confundida con “S”. En contraste, las señas “Bien” y “R” presentaron una tasa de error del 100%, sin clasificaciones correctas (Figura 38).

Matriz de confusión — Quadratic SVM (100 muestras RMS por seña)




Figura 38. Validación de Quadratic SVM entrenado con 100 muestras RMS por seña (BIOPAC MP36) al ser probado con un nuevo set de datos

El modelo *Medium Gaussian SVM* fue entrenado con 100 muestras crudas por seña (MyoWare) y validado con un nuevo conjunto de datos obtenido con el Myoware Muscle Sensor 2.0. En este caso, solo la seña “R” fue correctamente identificada en todas sus repeticiones (5/5 aciertos, 0% de error), mientras que las señas “Bien”, “C”, “Hola” y “S” registraron una tasa de error del 100%, siendo clasificadas erróneamente como “R” en todos los casos (Figura 39).

Matriz de confusión — Medium Gaussian SVM (100 muestras crudas por seña)




Figura 39. Validación de *Medium Gaussian SVM* entrenado con 100 muestras crudas por seña (MyoWare Muscle Sensor 2.0) al ser probado con un nuevo set de datos

Durante la etapa de validación se comparó el desempeño de los modelos con mayor precisión en el entrenamiento. El modelo *Cubic SVM* (Biopac crudo) identificó correctamente 5 gestos y presentó 20 errores. El *Quadratic SVM* (Biopac crudo) obtuvo 8 aciertos y 17 clasificaciones incorrectas, mientras que el *Linear Discriminant* (Biopac crudo) alcanzó 5 aciertos y 20 errores. En el caso del *Quadratic SVM* (Biopac RMS), se lograron 9 aciertos y 16 errores, mostrando un desempeño ligeramente superior al de los modelos anteriores. Finalmente, el *Medium Gaussian SVM* (MyoWare crudo) presentó 5 aciertos y 20 errores (Figura 40).




Figura 40. Comparación general de aciertos y errores en la etapa de validación de los modelos de clasificación

El presente estudio tuvo como propósito evaluar la capacidad de reconocimiento de gestos del lenguaje de señas mediante algoritmos de *Machine Learning*, a partir de señales electromiográficas (EMG) adquiridas con los sistemas BIOPAC y Myoware 2.0. A través de diferentes etapas de procesamiento (incluyendo el filtrado digital, la rectificación y el cálculo de la envolvente RMS) se buscó determinar qué tipo de señal y configuración de adquisición optimizaban el rendimiento de los modelos de clasificación. La discusión interpreta los resultados desde una perspectiva fisiológica y computacional, analizando la morfología y reproducibilidad de las señales, el desempeño de los clasificadores según el tipo de dato (crudo o procesado), la comparación entre sensores, y la influencia del número de canales en la precisión del modelo, con el fin de contextualizar los hallazgos dentro de los principios teóricos de la electromiografía y la literatura actual en reconocimiento de patrones bioeléctricos.

9.1. Morfología y reproducibilidad de las señales EMG

Las señales EMG crudas adquiridas mediante el sistema BIOPAC mostraron una morfología coherente con los patrones fisiológicos de activación muscular voluntaria, evidenciando picos irregulares de amplitud y variabilidad entre canales que reflejan la naturaleza del reclutamiento de unidades motoras (Figura 24). Esta variabilidad se atribuye a la diferente profundidad y orientación de los músculos implicados en cada gesto, así como a la distancia entre los electrodos y la fuente de señal. En el gesto “C”, la baja amplitud y la forma de onda estable sugieren una contracción corta y localizada, mientras que en “Hola” la mayor densidad y continuidad temporal indican la participación simultánea de varios grupos musculares y un esfuerzo sostenido. Estos patrones son consistentes ya que señalan que la amplitud y la estabilidad de la señal EMG están directamente relacionadas con el número y la sincronización de las unidades motoras activadas durante una contracción [47].

En contraste, las señales procesadas mediante la envolvente RMS presentaron una reducción significativa del ruido y una mejora en la visualización de la dinámica de activación

(Figura 24). Este comportamiento se explica porque la operación de rectificación y suavizado mediante ventana móvil atenúa las fluctuaciones de alta frecuencia, permitiendo observar la envolvente de energía muscular asociada al esfuerzo contráctil. El cálculo del valor cuadrático medio (RMS) proporciona una estimación robusta de la activación neuromuscular efectiva [48], facilitando la discriminación entre gestos debido a su estabilidad temporal y su menor sensibilidad al ruido. De forma similar, se ha demostrado que las señales RMS mejoran la consistencia entre repeticiones al eliminar artefactos transitorios y conservar la información relevante de la fuerza y duración de la contracción [49].

La diferencia en la morfología y reproducibilidad entre las señales crudas y procesadas confirma la relevancia del preprocesamiento para la clasificación precisa de gestos mediante algoritmos de aprendizaje automático. En este estudio, el filtrado pasa-banda Butterworth de cuarto orden con frecuencias de corte entre 20 Hz y 450 Hz permitió eliminar artefactos de movimiento y ruido de alta frecuencia, preservando la morfología esencial de los potenciales de acción musculares. Este tipo de filtrado ha sido empleado en estudios con resultados similares, los cuales reportaron mejoras significativas en la precisión de reconocimiento al utilizar técnicas de suavizado y extracción de características sobre señales EMG preprocesadas [50].

En las señales EMG crudas registradas con el MyoWare Muscle Sensor 2.0 (Figura 25), se observan amplitudes significativamente mayores que en el BIOPAC MP36, debido al amplificador integrado del sensor, con una ganancia aproximada de 200 veces. Esto explica los valores más altos en el eje “y”, pues el MyoWare entrega una señal ya acondicionada y amplificada. En comparación con Biopac, las señales presentan más ruido y variabilidad entre canales, atribuibles a la baja frecuencia de muestreo (100 Hz), el ruido del ADC y la sensibilidad al contacto piel-electrodo, factores que reducen la relación señal-ruido [51]. Aun así, la morfología general es coherente, evidenciando una reproducibilidad aceptable para la clasificación de gestos.

9.2. Desempeño de los modelos de *machine learning* con señales crudas – BIOPAC MP36

Para el set de datos de señales EMG en crudo adquiridas con el sistema BIOPAC MP36, cuando se utilizaron 100 muestras por seña, los modelos *Quadratic SVM* y *Cubic SVM* alcanzaron precisiones de 99.4% (Figura 26). Este alto desempeño se explica porque estos modelos de kernel permiten mapear las características en un espacio de mayor dimensión, capturando con precisión las fronteras no lineales entre clases [52] [53]. La mayor cantidad de muestras permitió estimar con fiabilidad el margen máximo y construir hiperplanos más estables, lo que es una de las fortalezas teóricas del SVM [54].

Al reducir el tamaño del conjunto a 50 muestras por seña, se observó que el modelo *Linear Discriminant* (LDA) mejoró ligeramente su precisión (99.6%), superando incluso el rendimiento de los SVM en esta condición. Esta mejora puede explicarse porque un clasificador lineal como *Linear Discriminant* requiere estimaciones de covarianza y medias de clases que son más robustas cuando el número de parámetros es pequeño en comparación al número de observaciones, evitando el efecto sobreajuste [55].

Finalmente, con sólo 25 muestras por seña, los modelos *Linear Discriminant* y *Quadratic*

SVM lograron una precisión del 100 % (Figura 26). Este patrón indica que la información discriminante esencial estaba bien representada aun en un número reducido de muestras y que el modelo LDA, al tener menos complejidad, consiguió una generalización óptima con esos datos limitados [53].

Los modelos *Boosted Trees* y *RUSBoosted Trees* presentaron un desempeño consistentemente bajo (Figura 26). Esto se debe a que los árboles de decisión son altamente sensibles al ruido, artefactos y variabilidad de las señales EMG. En este tipo de datos, las oscilaciones rápidas y la falta de suavizado dificultan la identificación de patrones estables, provocando que los algoritmos de boosting se sobreajusten a valores atípicos o ruido local [56]. Además, el submuestreo aleatorio del método RUSBoost elimina ejemplos representativos en conjuntos pequeños, reduciendo aún más su capacidad de generalización [57].

9.3. Desempeño de los modelos de *machine learning* con señales RMS – BIOPAC MP36

Cuando se emplearon señales EMG procesadas mediante la envolvente RMS, se observó un patrón diferenciado en el desempeño de los modelos conforme al tamaño del conjunto de muestras (Figura 28). Con 100 muestras por seña, los clasificadores *Quadratic SVM* y *Quadratic Discriminant* lograron precisiones de 97.4 % y 97.2 %, respectivamente, lo que indica que incluso tras la rectificación y suavizado de la señal (que reduce ruido pero también parte de la variabilidad de la señal original) los modelos capaces de capturar relaciones no lineales alcanzan un excelente desempeño. Esto se explica por la capacidad de dichos clasificadores para manejar espacios de características donde las fronteras entre clases pueden requerir curvaturas o combinaciones complejas [47][48].

Al reducir el conjunto a 50 muestras por seña, el modelo *Linear Discriminant* alcanzó una precisión de 98 %, seguido por *Subspace Discriminant* con 97.6 % (Figura 28). Este avance relativo puede atribuirse a que la naturaleza lineal del modelo se ajusta bien cuando las características extraídas (RMS) presentan buena separabilidad y la dimensionalidad del espacio de entrenamiento no crece en exceso. En contextos de menor cantidad de datos, los modelos menos complejos tienden a generalizar mejor y evitan el sobreajuste [53].

Con apenas 25 muestras por seña, los modelos *Cubic SVM* y *Quadratic SVM* mantuvieron una precisión de 98.4 % cada uno (Figura 28). Este resultado sugiere que, aun con un volumen reducido de datos, la consistencia de la envolvente RMS (gracias a la reducción del ruido y la mejora de reproducibilidad) permitió que los clasificadores complejos funcionaran de forma efectiva.

Los clasificadores *Boosted Trees* y *RUSBoosted Trees* mantuvieron una precisión baja con 50 y 25 muestras por seña (Figura 28). Aunque el RMS mejora la suavidad y reduce el ruido, también disminuye la complejidad espectral y la variabilidad entre clases, lo que limita la cantidad de información disponible para construir divisiones efectivas en los árboles [56].

9.4. Desempeño de los modelos de *machine learning* con señales crudas – Myoware Muscle Sensor 2.0

En el set de datos en crudo obtenido con el MyoWare Muscle Sensor 2.0, los modelos de clasificación mostraron un rendimiento inferior al observado con el BIOPAC MP36, evidenciando la influencia del tipo de sensor y de las condiciones de adquisición sobre la calidad del EMG (Figura 30). Con 100 muestras por señal, los modelos *Medium Gaussian SVM* y *Bagged Trees* alcanzaron las mayores precisiones (91.8% y 91.2%), mientras que con 50 muestras, el *Cubic SVM* (92.8%) y el *Linear SVM* (92.4%) mantuvieron una estabilidad relativa; los métodos de boosting, en cambio, descendieron a 48.4%. Con 25 muestras, el *Linear Discriminant* y el *Linear SVM* alcanzaron 89.6% y 87.2%, respectivamente, frente al 20% de los árboles de decisión (Figura 30).

Estas variaciones se explican por limitaciones intrínsecas del MyoWare, como su frecuencia de muestreo más baja (100 Hz frente a 2 kHz del BIOPAC MP36), el ruido del convertidor ADC del Arduino, y la susceptibilidad a interferencias por movimiento y contacto piel-electrodo [51]. Dichos factores reducen la relación señal-ruido y la estabilidad de las contracciones, afectando la discriminación de gestos. Asimismo, los sensores de bajo costo presentan variabilidad intercanal y menor profundidad de detección muscular, lo que debilita la segmentación del esfuerzo eléctrico [58]. Por ello, los clasificadores *SVM* y *Discriminant* mantienen un desempeño superior, gracias a su robustez frente al ruido y su capacidad para modelar límites no lineales en espacios multidimensionales [59].

9.5. Desempeño de los modelos de *machine learning* ante la disminución de canales para entrenamiento

La reducción del número de canales en el entrenamiento de los modelos impactó directamente la precisión de clasificación, aunque con variaciones según el tipo de señal y sensor. En el set de datos en crudo del BIOPAC MP36 (Figura 32), los modelos *Quadratic SVM* y *Cubic SVM* mantuvieron altos niveles de precisión al pasar de tres a un canal (99.4% a 94.4%), demostrando su capacidad para modelar fronteras de decisión no lineales incluso con menor información de entrada [49]. En contraste, los *Boosted Trees* y *RUSBoosted Trees* presentaron una disminución marcada, lo que evidencia su dependencia de un número mayor de variables para construir reglas de decisión robustas y evitar sobreajuste [56].

En el set RMS del BIOPAC (Figura 33), la reducción de canales afectó con mayor intensidad a los algoritmos basados en distancia, como *KNN*, cuya precisión descendió hasta 43.4%. Esta caída se debe a la pérdida de información espacial sobre la activación muscular entre canales, que resulta esencial para distinguir contracciones similares [59]. Aun así, los *SVM* y *Discriminant* conservaron entre 97.4% y 86.6%, gracias a su robustez ante datos suavizados y su capacidad de generalizar en entornos de baja variabilidad [60].

Por su parte, en el set de MyoWare crudo (Figura 34), la precisión se redujo de 91.8% con tres canales a solo 46% con uno. Este deterioro se atribuye a limitaciones instrumentales, como la frecuencia de muestreo reducida (100 Hz frente a 2 kHz del Biopac), el ruido del convertidor ADC del Arduino y la inestabilidad del contacto piel-electrodo, factores que

incrementan el ruido y distorsionan los patrones musculares [51].

9.6. Validación de los modelos con precisión más alta

Durante la etapa de validación, todos los modelos presentaron una disminución significativa en la precisión respecto a las fases de entrenamiento (Figura 40), fenómeno común en estudios de reconocimiento de gestos mediante EMG. Esta caída puede atribuirse principalmente a que los nuevos conjuntos de datos se registraron en sesiones diferentes, lo que implica variaciones en la colocación de los electrodos, cambios en la impedancia de la piel y diferencias en las condiciones fisiológicas del músculo y la temperatura cutánea entre días. Estas variaciones alteran la distribución espacial y espectral de la señal, afectando la reproducibilidad de las características extraídas [61] [62]. Asimismo, se ha documentado que incluso desviaciones menores en la posición de los electrodos pueden modificar significativamente la relación señal-ruido y la forma de onda de los potenciales de acción detectados [59].

De igual forma, la impedancia de la piel y el estado de hidratación del tejido influyen en la conductividad eléctrica y, por tanto, en la amplitud y estabilidad de la señal EMG [22]. Estos factores introducen una variabilidad entre sesiones que limita la capacidad de los modelos entrenados para generalizar a nuevas condiciones experimentales, especialmente cuando no se aplican estrategias de recalibración o normalización entre sesiones [63].

El presente trabajo tuvo como propósito desarrollar un sistema de reconocimiento del lenguaje de señas en español a partir de señales electromiográficas (EMG), empleando técnicas de procesamiento digital y algoritmos de *machine learning*. A través de la captura de datos con los sistemas BIOPAC MP36 y MyoWare Muscle Sensor 2.0, se evaluó la influencia del tipo de señal, sensor y número de canales sobre la precisión de los modelos de clasificación, con el objetivo de determinar las condiciones que optimizan el reconocimiento de gestos musculares.

- Se logró desarrollar un banco de cinco señas (“Bien”, “Hola”, “C”, “R” y “S”) y obtener registros reproducibles utilizando un BIOPAC MP 36 y MyoWare Muscle Sensor 2.0. Las señales EMG capturadas con el sistema BIOPAC presentaron una morfología coherente con la fisiología muscular y una adecuada relación señal-ruido, mientras que las señales adquiridas con MyoWare mostraron amplitudes más altas debido a la ganancia integrada de los sensores, aunque con mayor variabilidad. Este conjunto de datos permitió disponer de información electromiográfica claramente diferenciable entre gestos, cumpliendo el objetivo de generar un set de datos funcional y representativo para el entrenamiento de los modelos de clasificación.
- Los modelos de clasificación entrenados con señales BIOPAC alcanzaron precisiones superiores al 99 %, destacando los clasificadores *Quadratic SVM*, *Cubic SVM* y *Linear Discriminant* por su capacidad de generalización incluso con conjuntos de datos reducidos. En el caso de los sensores MyoWare, el modelo *Medium Gaussian SVM* obtuvo la mayor precisión, superando el 91 % y demostrando un desempeño estable en la clasificación de gestos musculares. Por otro lado, los modelos basados en árboles de decisión presentaron un rendimiento limitado (20 %) con ambos sistemas, evidenciando que las señales EMG requieren clasificadores robustos capaces de resistir el ruido y la variabilidad entre canales.
- Se lograron validar los modelos y algoritmos con mejor precisión durante la etapa de entrenamiento con sets de datos nuevos. Los resultados obtenidos evidenciaron una

disminución en la precisión durante la etapa de validación, atribuida principalmente a la variabilidad entre sesiones de registro. Aun así, los resultados confirmaron que el modelo *Quadratic SVM*, entrenado con 100 muestras crudas por seña con BIOPAC, fue el más adecuado para el reconocimiento de gestos EMG en condiciones controladas, logrando identificar correctamente 9 de 25 señales. Esto demuestra su potencial como base para futuras mejoras en la estabilidad y generalización del sistema.

Aunque el sistema desarrollado logró reconocer señas básicas del lenguaje de señas en español con altos niveles de precisión bajo condiciones controladas, el trabajo aún no se considera concluido debido a las limitaciones observadas durante la etapa de validación. La variabilidad entre cada sesión derivada de la recolocación de electrodos, los cambios en la impedancia de la piel y la estabilidad del contacto piel-electrodo afectaron la generalización de los modelos de *machine learning*, reduciendo su rendimiento en nuevas sesiones de captura.

Por ello, el trabajo futuro se orientará a mejorar la estabilidad y adaptabilidad del sistema, mediante la optimización del proceso de adquisición de señal, la exploración de métodos de recalibración automática y la integración de algoritmos más robustos, capaces de operar en tiempo real y con distintos usuarios. Estas mejoras permitirán transicionar de un entorno experimental controlado hacia una plataforma funcional con potencial de aplicación en contextos de accesibilidad comunicativa.

11.1. Identificación de limitaciones actuales

En primer lugar, la variabilidad entre cada sesión fue el principal factor que afectó la reproducibilidad de los modelos. Pequeñas diferencias en la colocación de los electrodos, cambios en la impedancia de la piel o variaciones fisiológicas entre sesiones alteraron la morfología de las señales. Esto provocó que los modelos previamente entrenados perdieran capacidad de generalización.

En segundo lugar, el sensor MyoWare Muscle Sensor 2.0 presentó limitaciones instrumentales asociadas a su baja frecuencia de muestreo (100 Hz), su sensibilidad al ruido ambiental y su dependencia del contacto piel-electrodo. Estas condiciones reducen la estabilidad del registro, lo que dificulta la obtención de patrones electromiográficos consistentes en gestos de corta duración. Por esta razón, los modelos entrenados con estos sensores obtuvieron precisiones más bajas.

El sistema multicanal BIOPAC MP36 ofreció alta resolución y bajo nivel de ruido, garantizando señales de excelente calidad. Sin embargo, su costo y uso restringido a entornos de laboratorio limitan su aplicabilidad práctica. Además, la falta de un mecanismo de recalibración automática entre sesiones impide la adaptación del modelo a diferentes usuarios o condiciones experimentales.

Finalmente, el sistema no se integró en tiempo real, ya que el procesamiento y la clasificación se realizaron de forma offline. Esta limitación impidió evaluar la latencia, la velocidad de respuesta y el desempeño del sistema en condiciones dinámicas. Tales parámetros resultan fundamentales para su implementación futura en un dispositivo portátil o interfaz interactiva.

11.2. Propuestas concretas de mejora o investigación

Se propone implementar un mecanismo de recalibración intersesión automatizada que permita compensar las variaciones en la colocación de los electrodos y en la impedancia de la piel entre sesiones. Este proceso podría consistir en una breve rutina de calibración inicial, donde el sistema registre señales en reposo y repeticiones controladas de cada seña para normalizar las características de entrada. La inclusión de este bloque de recalibración, ya sea en MATLAB o con un sistema de adquisición MCU más poderoso, permitiría ajustar los parámetros de cada sesión y mejorar la capacidad de generalización del modelo sin requerir un reentrenamiento completo.




Figura 41. Flujo del proceso de recalibración entre sesiones para el reconocimiento de señas EMG en tiempo real

También se propone optimizar el sistema de adquisición de bajo costo sustituyendo el Arduino UNO por una plataforma que integre un convertidor analógico-digital (ADC) externo de mayor resolución y frecuencia de muestreo. En la configuración actual, el uso del ADC interno del Arduino limitó la tasa de muestreo a aproximadamente 100 Hz, lo que redujo la capacidad para registrar adecuadamente la dinámica rápida de los potenciales musculares. La incorporación de un ADC dedicado de 16 a 24 bits y al menos 1 kHz por canal permitiría capturar señales con menor ruido y mayor precisión, obteniendo registros más estables y representativos, especialmente en gestos breves o de baja amplitud electromiográfica. Asimismo, se considera viable el uso de un microcontrolador más potente ya que ofrecería mejor

procesamiento, mayor velocidad de muestreo y resolución ADC superior, facilitando la implementación de un sistema EMG más rápido, preciso y adaptable a aplicaciones en tiempo real.




Figura 42. Propuesta de mejora del sistema de adquisición EMG mediante ADC externo de alta resolución

También se sugiere investigar métodos que aumenten la estabilidad del sistema entre distintas sesiones y usuarios. Una opción es normalizar las señales con base en la contracción voluntaria máxima (MVC) de cada persona, para que las amplitudes registradas sean comparables incluso cuando cambie la intensidad del gesto o la posición de los electrodos. Otra alternativa es aplicar técnicas de alineación de dominios, que ajustan las características de las señales para reducir las diferencias entre días de registro o individuos. Con estas estrategias, el modelo podría entrenarse con datos de varias personas y conservar una precisión estable al enfrentarse a nuevas condiciones de registro. Complementariamente, se recomienda ampliar el conjunto de señas y el número de muestras por clase, con el fin de fortalecer la capacidad de generalización del modelo y representar una mayor diversidad de patrones musculares. El incremento del volumen de datos permitiría entrenar clasificadores más robustos y reducir el riesgo de sobreajuste observado en conjuntos limitados. Además, se sugiere equilibrar el número de repeticiones por seña y registrar variaciones naturales en la ejecución de cada gesto, lo que contribuiría a desarrollar un sistema más adaptable a diferentes usuarios y condiciones experimentales. A partir de las mejoras planteadas, el sistema podría evolucionar hacia una versión portátil capaz de operar en tiempo real. Estas adaptaciones permitirían adquirir, procesar y clasificar las señales EMG directamente en un microcontrolador, mostrando la seña reconocida de forma inmediata en una pantalla o a través de un altavoz. De esta manera, el proyecto avanzaría hacia una aplicación práctica orientada a la comunicación asistida y accesible.




Figura 43. Sistema de adquisición y traducción en tiempo real de señas EMG

Finalmente, se considera recomendable implementar modelos de clasificación basados en redes neuronales convolucionales (CNN). Estas redes pueden aprender automáticamente las características relevantes de las señales EMG, eliminando la necesidad de definir manualmente los parámetros de entrada. Su capacidad para extraer patrones espaciales y temporales permite mejorar la precisión y la generalización del sistema ante variaciones entre sesiones o usuarios. Además, las CNN han demostrado un excelente desempeño en tareas de reconocimiento de gestos en estudios anteriores, lo que las convierte en una alternativa prometedora para optimizar la robustez y escalabilidad del modelo propuesto.

-
- [1] J. B. Jepsen, D. Clerck, S. Lutalo-Kiingi y W. B. Mcgregor, *Sign Languages of the World*, IEEE, 2015.
 - [2] D. M. P. Gutiérrez, *VIVENCIA DE LA CONDICIÓN DE DISCAPACIDAD AUDITIVA EN JÓVENES DE 18 A 30 AÑOS EN LA REGIÓN CENTRAL DE GUATEMALA*, nov. de 2022.
 - [3] W. Li, Z. Luo, W. Li y X. Xi, «Chinese sign language recognition based on surface electromyography and motion information,» *PLOS ONE*, vol. 18, e0295398, 12 dic. de 2023, ISSN: 1932-6203. DOI: 10.1371/journal.pone.0295398.
 - [4] M. Atzori, M. Cognolato y H. Müller, «Deep Learning with Convolutional Neural Networks Applied to Electromyography Data: A Resource for the Classification of Movements for Prosthetic Hands,» *Frontiers in Neurorobotics*, vol. 10, sep. de 2016, ISSN: 1662-5218. DOI: 10.3389/fnbot.2016.00009.
 - [5] A. Filipowska et al., «Pattern Recognition in the Processing of Electromyographic Signals for Selected Expressions of Polish Sign Language,» *Sensors*, vol. 24, 20 oct. de 2024, ISSN: 14248220. DOI: 10.3390/s24206710.
 - [6] A. B. H. Amor, O. E. Ghoul y M. Jemni, *Sign Language Recognition Using the Electromyographic Signal: A Systematic Literature Review*, oct. de 2023. DOI: 10.3390/s23198343.
 - [7] Z. K. Senturk y M. S. Bakay, «Machine Learning Based Hand Gesture Recognition via EMG Data,» *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, vol. 10, 2 mar. de 2021. DOI: 10.14201/adcaij2021102123136.
 - [8] A. Rahagiyanto, G. E. J. Suyoso, V. Vestine y A. Iskandar, «Prototype of MyoWare (Electromyography Muscle Sensor) for Measuring People's Muscle Strengths,» *International Journal of Health and Information System*, vol. 1, págs. 19-26, 1 mayo de 2023. DOI: 10.47134/ijhis.v1i1.9.
 - [9] O. M. de la Salud, *Sordera y pérdida de la audición*, feb. de 2022. dirección: <https://www.who.int/es/news-room/fact-sheets/detail/deafness-and-hearing-loss?utm>.

- [10] M. Palma, *LENSEGUA, LEY QUE FOMENTA LA INCLUSIÓN SOCIAL*, sep. de 2022. dirección: https://www.congreso.gob.gt/noticias_congreso/9131/2022/4?utm_.
- [11] A. Loza, G. Formentí, A. Meza, H. Karla y M. E. Magallanes, *INFORME GUATEMALA*, 2022. dirección: <https://www.riadis.org/wp-content/uploads/2022/10/INFORME-GUATEMALA-F-Accessible-1.pdf>.
- [12] A. R. Villa, «El-lenguaje-de-se-as-en-un-mundo-globalizado_Alejandra-Ruiz-Villa_VBLOG_{f3},» ago. de 2021. dirección: <https://es.scribd.com/document/532884133/El-Lenguaje-de-Senas-en-Un-Mundo-Globalizado-Alejandra-Ruiz-Villa-VBLOG-f-3>.
- [13] Showleap, *Showleap es una herramienta muy potente para proporcionar autonomía a las personas sordas*, 2018. dirección: https://www.fundaciononce.es/sites/default/files/showleap_la_razon_24_sep.pdf.
- [14] C. Europea, *Tecnologías de inteligencia artificial para personas sordas o con deficiencia auditiva | aiD Project | Results in brief | H2020 | CORDIS | European Commission*, 2018. dirección: <https://cordis.europa.eu/article/id/450232-ai-solutions-for-the-deaf-and-hard-of-hearing>.
- [15] S. Jimshelishvili, K. Marwaha y A. L. Sherman, *Physiology, Neuromuscular Transmission*, Overview chapter; PMID: 31082177, 2025.
- [16] C. Chen, D. Li y M. Xia, «A motor unit action potential-based method for surface electromyography decomposition,» *Journal of NeuroEngineering and Rehabilitation*, vol. 22, 1 dic. de 2025, ISSN: 17430003. DOI: 10.1186/s12984-025-01595-y.
- [17] E. L. Berne, W. F. Boron y E. L. Boulpaep, *Fisiología Médica*, 3.^a ed. Elsevier, 2017, págs. 204-208, Traducción de Boron & Boulpaep.
- [18] P. Verma, A. Kienle, D. Flockerzi y D. Ramkrishna, «Using Bifurcation Theory for Exploring Pain,» *Industrial Engineering Chemistry Research*, vol. 59, págs. 2524-2535, 6 feb. de 2020, ISSN: 0888-5885. DOI: 10.1021/acs.iecr.9b04495.
- [19] M. Al-Ayyad, H. A. Owida, R. D. Fazio, B. Al-Naami y P. Visconti, «Electromyography Monitoring Systems in Rehabilitation: A Review of Clinical Applications, Wearable Devices and Signal Acquisition Methodologies,» *Electronics*, vol. 12, pág. 1520, 7 mar. de 2023, ISSN: 2079-9292. DOI: 10.3390/electronics12071520.
- [20] Y. Fu, J. Zhao, Y. Dong y X. Wang, «Dry Electrodes for Human Bioelectrical Signal Monitoring,» *Sensors*, vol. 20, pág. 3651, 13 jun. de 2020, ISSN: 1424-8220. DOI: 10.3390/s20133651.
- [21] M. Gomez-Correa y D. Cruz-Ortiz, «Low-Cost Wearable Band Sensors of Surface Electromyography for Detecting Hand Movements,» *Sensors*, vol. 22, 16 ago. de 2022, ISSN: 14248220. DOI: 10.3390/s22165931.
- [22] R. Merletti y D. Farina, *Surface Electromyography : Physiology, Engineering, and Applications*, R. Merletti y D. Farina, eds. Wiley, abr. de 2016, ISBN: 9781118987025. DOI: 10.1002/9781119082934.
- [23] B. B. Etana, B. Malengier, K. Timothy, S. Wojciech, J. Krishnamoorthy y L. V. Langenhove, «A review on the recent developments in design and integration of electromyography textile electrodes for biosignal monitoring,» *Journal of Industrial Textiles*, vol. 53, sep. de 2023, ISSN: 1528-0837. DOI: 10.1177/15280837231175062.

- [24] C. J. D. Luca, «The Use of Surface Electromyography in Biomechanics,» *Journal of Applied Biomechanics*, vol. 13, págs. 135-163, 2 mayo de 1997, ISSN: 1065-8483. DOI: 10.1123/jab.13.2.135.
- [25] A. Phinyomark, C. Limsakul, P. Phukpattaranont y P. Phukpattaranont, *A Novel Feature Extraction for Robust EMG Pattern Recognition*, 2009.
- [26] N. Malešević, D. Marković, G. Kanitz, M. Controzzi, C. Cipriani y C. Antfolk, «Vector Autoregressive Hierarchical Hidden Markov Models for Extracting Finger Movements Using Multichannel Surface EMG Signals,» *Complexity*, vol. 2018, 2018, ISSN: 10990526. DOI: 10.1155/2018/9728264.
- [27] A. D. Vigotsky, I. Halperin, G. J. Lehman, G. S. Trajano y T. M. Vieira, «Interpreting Signal Amplitudes in Surface Electromyography Studies in Sport and Rehabilitation Sciences,» *Frontiers in Physiology*, vol. 8, ene. de 2018, ISSN: 1664-042X. DOI: 10.3389/fphys.2017.00985.
- [28] M. Boyer, L. Bouyer, J.-S. Roy y A. Campeau-Lecours, *A Real-Time Algorithm to Estimate Shoulder Muscle Fatigue Based on Surface EMG Signal For Static and Dynamic Upper Limb Tasks*.
- [29] A. M. Castronovo, C. D. Marchis, M. Schmid, S. Conforto y G. Severini, «Effect of Task Failure on Intermuscular Coherence Measures in Synergistic Muscles,» *Applied Bionics and Biomechanics*, vol. 2018, págs. 1-13, jun. de 2018, ISSN: 1176-2322. DOI: 10.1155/2018/4759232.
- [30] C. Bishop, *Pattern Recognition and Machine Learning*, 1.^a ed. Springer, 2006.
- [31] R. Guido, S. Ferrisi, D. Lofaro y D. Conforti, «An Overview on the Advancements of Support Vector Machine Models in Healthcare Applications: A Review,» *Information*, vol. 15, pág. 235, 4 abr. de 2024, ISSN: 2078-2489. DOI: 10.3390/info15040235.
- [32] R. K. Halder, M. N. Uddin, M. A. Uddin, S. Aryal y A. Khraisat, «Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications,» *Journal of Big Data*, vol. 11, pág. 113, 1 ago. de 2024, ISSN: 2196-1115. DOI: 10.1186/s40537-024-00973-y.
- [33] E. O. Kiyak, B. Ghasemkhani y D. Birant, «High-Level K-Nearest Neighbors (HLKNN): A Supervised Machine Learning Model for Classification Analysis,» *Electronics*, vol. 12, pág. 3828, 18 sep. de 2023, ISSN: 2079-9292. DOI: 10.3390/electronics12183828.
- [34] I. D. Mienye y T. G. Swart, «A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications,» *Information*, vol. 15, pág. 755, 12 nov. de 2024, ISSN: 2078-2489. DOI: 10.3390/info15120755.
- [35] L. W. Rizkallah, «Enhancing the performance of gradient boosting trees on regression problems,» *Journal of Big Data*, vol. 12, pág. 35, 1 feb. de 2025, ISSN: 2196-1115. DOI: 10.1186/s40537-025-01071-3.
- [36] T. Zhang et al., «Improving Convection Trigger Functions in Deep Convective Parameterization Schemes Using Machine Learning,» *Journal of Advances in Modeling Earth Systems*, vol. 13, 5 mayo de 2021, ISSN: 1942-2466. DOI: 10.1029/2020MS002365.
- [37] A. Esteva et al., «Dermatologist-level classification of skin cancer with deep neural networks,» *Nature*, vol. 542, págs. 115-118, 7639 feb. de 2017, ISSN: 0028-0836. DOI: 10.1038/nature21056.

- [38] P. Rajpurkar et al., «Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists,» *PLoS Medicine*, vol. 15, 11 nov. de 2018, ISSN: 15491676. DOI: 10.1371/journal.pmed.1002686.
- [39] A. Y. Hannun et al., «Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network,» *Nature Medicine*, vol. 25, págs. 65-69, 1 ene. de 2019, ISSN: 1078-8956. DOI: 10.1038/s41591-018-0268-3.
- [40] E. J. Topol, «High-performance medicine: the convergence of human and artificial intelligence,» *Nature Medicine*, vol. 25, págs. 44-56, 1 ene. de 2019, ISSN: 1078-8956. DOI: 10.1038/s41591-018-0300-7.
- [41] A. Meisami, J. Deglise-Hawkinson, M. Cowen y M. P. V. Oyen, «Data-Driven Optimization Methodology for Admission Control in Critical Care Units,» *SSRN Electronic Journal*, 2016, ISSN: 1556-5068. DOI: 10.2139/ssrn.2838477.
- [42] M. Popova, O. Isayev y A. Tropsha, «Deep reinforcement learning for de novo drug design,» *Science Advances*, vol. 4, 7 jul. de 2018, ISSN: 2375-2548. DOI: 10.1126/sciadv.aap7885.
- [43] A. Zhavoronkov et al., «Deep learning enables rapid identification of potent DDR1 kinase inhibitors,» *Nature Biotechnology*, vol. 37, págs. 1038-1040, 9 sep. de 2019, ISSN: 1087-0156. DOI: 10.1038/s41587-019-0224-x.
- [44] D. Farina et al., «The Extraction of Neural Information from the Surface EMG for the Control of Upper-Limb Prostheses: Emerging Avenues and Challenges,» *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 22, págs. 797-809, 4 jul. de 2014, ISSN: 1534-4320. DOI: 10.1109/TNSRE.2014.2305111.
- [45] Z. Zhang, Q. Shen e Y. Wang, «Electromyographic hand gesture recognition using convolutional neural network with multi-attention,» *Biomedical Signal Processing and Control*, vol. 91, pág. 105935, mayo de 2024, ISSN: 17468094. DOI: 10.1016/j.bspc.2023.105935.
- [46] E. Escobar, *Desarrollo de material visual que promueva la introducción de personas oyentes en el aprendizaje de la lengua de señas de Guatemala*, Constancia de Proyecto de Grado, 2022.
- [47] M. Montazerin, E. Rahimian, F. Naderkhani, S. F. Atashzar, S. Yanushkevich y A. Mohammadi, «Transformer-based hand gesture recognition from instantaneous to fused neural decomposition of high-density EMG signals,» *Scientific Reports*, vol. 13, 1 dic. de 2023, ISSN: 20452322. DOI: 10.1038/s41598-023-36490-w.
- [48] G. Yu, Z. Deng, Z. Bao, Y. Zhang y B. He, «Gesture Classification in Electromyography Signals for Real-Time Prosthetic Hand Control Using a Convolutional Neural Network-Enhanced Channel Attention Model,» *Bioengineering*, vol. 10, pág. 1324, 11 nov. de 2023, ISSN: 2306-5354. DOI: 10.3390/bioengineering10111324.
- [49] M. H. Abdelaziz, W. A. Mohamed y A. S. Selmy, «Hand Gesture Recognition Based on Electromyography Signals and Deep Learning Techniques,» *Journal of Advances in Information Technology*, vol. 15, págs. 255-263, 2 2024, ISSN: 17982340. DOI: 10.12720/jait.15.2.255-263.

- [50] H. G. M. Qamar et al., «EMG gesture signal analysis towards diagnosis of upper limb using dual-pathway convolutional neural network,» *Mathematical Biosciences and Engineering*, vol. 21, págs. 5712-5734, 4 2024, ISSN: 1551-0018. DOI: 10.3934/mbe.2024252.
- [51] C. Wu, Y. Yan, Q. Cao, F. Fei, D. Yang y A. Song, «A Low Cost Surface EMG Sensor Network for Hand Motion Recognition,» en *2018 IEEE 1st International Conference on Micro/Nano Sensors for AI, Healthcare, and Robotics (NSENS)*, IEEE, dic. de 2018, págs. 35-39, ISBN: 978-1-5386-9408-4. DOI: 10.1109/NSENS.2018.8713640.
- [52] D. C. Toledo-Pérez, J. Rodríguez-Reséndiz, R. A. Gómez-Loenzo y J. C. Jauregui-Correa, «Support Vector Machine-Based EMG Signal Classification Techniques: A Review,» *Applied Sciences*, vol. 9, pág. 4402, 20 oct. de 2019, ISSN: 2076-3417. DOI: 10.3390/app9204402.
- [53] C. L. Kok, C. K. Ho, F. K. Tan e Y. Y. Koh, «Machine Learning-Based Feature Extraction and Classification of EMG Signals for Intuitive Prosthetic Control,» *Applied Sciences*, vol. 14, pág. 5784, 13 jul. de 2024, ISSN: 2076-3417. DOI: 10.3390/app14135784.
- [54] M. Aviles, L.-M. Sánchez-Reyes, R. Fuentes-Aguilar, D. Toledo-Pérez y J. Rodríguez-Reséndiz, «A Novel Methodology for Classifying EMG Movements Based on SVM and Genetic Algorithms,» *Micromachines*, vol. 13, pág. 2108, 12 nov. de 2022, ISSN: 2072-666X. DOI: 10.3390/mi13122108.
- [55] P. Ghane, N. Z. Naghsh y U. Braga-Neto, «Comparison of Classification Algorithms Towards Subject-Specific and Subject-Independent BCI,» ene. de 2021. dirección: <http://arxiv.org/abs/2012.12473>.
- [56] J. Song et al., «Effects of Different Feature Parameters of sEMG on Human Motion Pattern Recognition Using Multilayer Perceptrons and LSTM Neural Networks,» *Applied Sciences*, vol. 10, pág. 3358, 10 mayo de 2020, ISSN: 2076-3417. DOI: 10.3390/app10103358.
- [57] H. He e Y. Ma, eds., *Imbalanced Learning*. Wiley, jun. de 2013, ISBN: 9781118074626. DOI: 10.1002/9781118646106.
- [58] J. P. Vásquez, L. I. B. López, Á. L. V. Caraguay y M. E. Benalcázar, «A comparison of EMG-based hand gesture recognition systems based on supervised and reinforcement learning,» *Engineering Applications of Artificial Intelligence*, vol. 123, pág. 106327, ago. de 2023, ISSN: 09521976. DOI: 10.1016/j.engappai.2023.106327.
- [59] A. Phinyomark, P. Phukpattaranont y C. Limsakul, «Feature reduction and selection for EMG signal classification,» *Expert Systems with Applications*, vol. 39, págs. 7420-7431, 8 jun. de 2012, ISSN: 09574174. DOI: 10.1016/j.eswa.2012.01.102.
- [60] C. Seyidbayli, F. Salhi y E. Akdogan, «Comparison of machine learning algorithms for EMG signal classification,» *Periodicals of Engineering and Natural Sciences*, vol. 8, págs. 1165-1176, 2 2020, ISSN: 23034521. DOI: 10.21533/pen.v8i2.1293.g602.
- [61] R. N. Khushaba, M. Takruri, J. V. Miro y S. Kodagoda, «Towards limb position invariant myoelectric pattern recognition using time-dependent spectral features,» *Neural Networks*, vol. 55, págs. 42-58, jul. de 2014, ISSN: 08936080. DOI: 10.1016/j.neunet.2014.03.010.

- [62] P. Tsinganos, B. Cornelis, J. Cornelis, B. Jansen y A. Skodras, «Improved Gesture Recognition Based on sEMG Signals and TCN,» en *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, mayo de 2019, págs. 1169-1173, ISBN: 978-1-4799-8131-1. DOI: 10.1109/ICASSP.2019.8683239.
- [63] D. P. Leins, C. Gibas, R. Brück y R. Haschke, «Toward More Robust Hand Gesture Recognition on EIT Data,» *Frontiers in Neurorobotics*, vol. 15, ago. de 2021, ISSN: 1662-5218. DOI: 10.3389/fnbot.2021.659311.




Figura 44. Resultados de precisión de los modelos de *machine learning* entrenados con el conjunto de datos crudo de BIOPAC (100 muestras por seña)




Figura 45. Resultados de precisión de los modelos de *machine learning* entrenados con el conjunto de datos crudo de BIOPAC (50 muestras por seña)




Figura 46. Resultados de precisión de los modelos de *machine learning* entrenados con el conjunto de datos crudo de BIOPAC (25 muestras por seña)




Figura 47. Resultados de precisión de los modelos de *machine learning* entrenados con el conjunto de datos RMS de BIOPAC (100 muestras por seña)




Figura 48. Resultados de precisión de los modelos de *machine learning* entrenados con el conjunto de datos RMS de BIOPAC (50 muestras por seña)




Figura 49. Resultados de precisión de los modelos de *machine learning* entrenados con el conjunto de datos RMS de BIOPAC (25 muestras por seña)




Figura 50. Resultados de precisión de los modelos de *machine learning* entrenados con el conjunto de datos en crudo de MyoWare (100 muestras por seña)




Figura 51. Resultados de precisión de los modelos de *machine learning* entrenados con el conjunto de datos en crudo de MyoWare (50 muestras por seña)




Figura 52. Resultados de precisión de los modelos de *machine learning* entrenados con el conjunto de datos en crudo de MyoWare (25 muestras por seña)

