

# Diseño de un sistema de adquisición EMG orientado al desarrollo de prótesis mioeléctricas

*Design of an EMG acquisition system oriented to the development of myoelectric prostheses*

BSc. Yeison Manuel Arias Nuñez<sup>✉</sup><sup>1</sup>, PhD. Sandra Patricia Usaquen Perilla<sup>✉</sup><sup>1</sup>  
MBA. Mauricio Alejandro Gómez Figueroa<sup>✉</sup><sup>1</sup>

<sup>1</sup>  Universidad Militar Nueva Granada, Facultad de Ingeniería, Bogotá, Colombia.

Correspondencia: mauricio.gomez@unimilitar.edu.co

Recibido: 06 abril 2026. Revisado: 16 junio 2026. Aceptado: 25 julio 2026. Publicado: 29 julio 2026.

**Cómo citar:** Y. M. Arias Nuñez, S. P. Usaquen Perilla, and M. A. Gómez Figueroa, "Diseño de un sistema de adquisición EMG orientado al desarrollo de prótesis mioeléctricas", *Revista Colombiana de Tecnologías de Avanzada (RCTA)*, vol. 2, no. 48, pp. 190–198, jul. 2026, doi: [10.24054/rcta.v2i48.4406](https://doi.org/10.24054/rcta.v2i48.4406)

Esta obra está bajo una licencia internacional  
[Creative Commons Atribución-NoComercial 4.0](https://creativecommons.org/licenses/by-nc/4.0/).



**Resumen:** Este artículo describe el desarrollo e implementación de la adquisición y el procesamiento de señales de electromiografía (EMG) para la etapa de control de una prótesis mioeléctrica. Se establece un método para detectar y clasificar la actividad muscular con baja carga computacional y alta reproducibilidad, utilizando una arquitectura híbrida analógica-digital. La señal EMG pasa a través de un filtro pasivo RC de paso bajo y luego a un circuito comparador de ventana con circuitos integrados LM393, que clasifica la actividad eléctrica en tres niveles: reposo, contracción o contracción parcial. Esta clasificación genera señales de modulación por ancho de pulso (PWM) para el control del servomotor, teniendo como resultado de la implementación de filtro pasabanda Butterworth digital obteniendo valores de voltaje 0.1 V a la salida que pueden ser amplificados y obtener para la activación del servomotor un voltaje de 1.9 V, cumplido con el objetivo que es generar la dinámica de un actuador con elementos de bajo costo con posibilidad de aumentar el número de actuadores debido al uso de Raspberry Pi 4 que cuenta con puertos de entrada y salida.

**Palabras clave:** ingeniería de rehabilitación, acondicionamiento de señales, electromiografía de superficie (sEMG), sistemas embebidos, servomotor, Raspberry Pi.

**Abstract:** This article describes the development and implementation of electromyography (EMG) signal acquisition and processing for the control stage of a myoelectric prosthesis. A method is established for detecting and classifying muscle activity with low computational load and high reproducibility, using a hybrid analog-digital architecture. The EMG signal passes through a passive RC low-pass filter and then to a window comparator circuit with LM393 integrated circuits, which classifies the electrical activity into three levels: rest, contraction, or partial contraction. This classification generates pulse-width modulation (PWM) signals for servomotor control. The implementation of a digital Butterworth bandpass filter results in output voltages of 0.1 V, which can be amplified to obtain a 1.9 V voltage for servomotor activation. This fulfills the objective of generating the dynamics of an actuator with low-cost components, with the possibility of increasing the number of actuators due to the use of a Raspberry Pi 4, which has input/output ports.

**Keywords:** rehabilitation engineering, signal conditioning, surface electromyography (sEMG), embedded systems, servomotor, Raspberry Pi.

## 1. INTRODUCCIÓN

La amputación de miembros superiores es una patología que impacta negativamente la funcionalidad, la calidad de vida y la autonomía de quienes la padecen. Las causas más frecuentes asociadas a la amputación incluyen traumatismos, enfermedades vasculares, infecciones, tumores y malformaciones congénitas. En países en desarrollo, como Colombia, los pacientes amputados enfrentan dificultades para acceder a prótesis debido a la falta de tecnología de rehabilitación y al alto costo de las prótesis más avanzadas. En este contexto, las prótesis mioeléctricas han surgido como una alternativa interesante, ya que pueden registrar señales electromiográficas de superficie (EMG) de la actividad muscular para controlar actuadores mecánicos y otros mecanismos. Diversos estudios han demostrado una relación entre las señales EMG y la activación muscular, lo que ha llevado a su uso como interfaz entre el sistema neuromuscular y los dispositivos protésicos [1], [2].

Las señales EMG presentan varios desafíos debido a sus bajas amplitudes (de  $50\mu\text{V}$  a  $5\text{mV}$ ), su alta sensibilidad al ruido y su variabilidad entre usuarios y condiciones de medición. Por lo tanto, requieren etapas de acondicionamiento, filtrado y procesamiento para mejorar la calidad de la señal y facilitar su interpretación [2], [3]. En los últimos años, se han propuesto diversas técnicas de procesamiento y clasificación de señales EMG, incluyendo métodos básicos de aprendizaje automático y aprendizaje profundo que han alcanzado una alta precisión en el reconocimiento de gestos y patrones musculares [4], [5], [6].

Sin embargo, las arquitecturas presentadas suelen estar asociadas a una alta complejidad computacional, la necesidad de grandes volúmenes de datos para un entrenamiento adecuado y mayores requisitos de hardware, lo que puede limitar su integración en sistemas embebidos de bajo coste [7], [8], [9]. Por otro lado, se han propuesto arquitecturas simplificadas que utilizan técnicas de acondicionamiento analógico y estrategias de clasificación discreta, reduciendo la carga computacional sin comprometer el rendimiento del sistema [10].


Además de lo anterior, el uso de plataformas embebidas de bajo coste, como la Raspberry Pi (que ofrece un excelente rendimiento de microcontrolador), ha permitido el desarrollo de sistemas de muy bajo coste para la adquisición, el control y el procesamiento en tiempo real de señales biomédicas [11], [12]. De hecho, estas plataformas integradas ofrecen una solución flexible y escalable para la implementación de sistemas y dispositivos de soporte en entornos académicos y de investigación.

A pesar de estos avances, persisten desafíos en cuanto a la estabilidad de la señal del sistema y la identificación fiable de los estados de activación muscular en situaciones operativas [13]. Además, el presente trabajo propone el diseño y prototipado de un sistema de adquisición y control de señales EMG basado en una arquitectura híbrida analógica-digital de muy bajo coste, que permite la clasificación discreta de los estados de contracción muscular y su uso común en el control de prótesis mioeléctricas.

## 2. MATERIALES Y MÉTODOS

### 2.1. Arquitectura del sistema

El sistema propuesto combina etapas analógicas y digitales para adquirir, clasificar y controlar señales sEMG destinadas a futuras aplicaciones en prótesis mioeléctricas.



**Fig. 1.** Diagrama general del sistema de adquisición de EMG y control mioeléctrico. **Fuente:** elaboración propia.

Como se muestra en la Fig 1, la arquitectura consta de un sensor EMG de superficie, una etapa de acondicionamiento analógico, un comparador de ventana que utiliza el LM393, un convertidor analógico-digital MCP3008, una unidad de procesamiento que ejecuta Python en una Raspberry Pi 4 y un servomotor INJORA como actuador final.

La señal EMG, utilizada como referencia por el músculo bíceps, es capturada por electrodos de superficie y acondicionada para mejorar su estabilidad. El comparador lee la señal y clasifica los niveles de contracción muscular. Esta misma señal se discretiza para su almacenamiento, y la Raspberry Pi 4, mediante programación, puede identificar los estados detectados y enviar señales de control al actuador.

## 2.2. Implementación de hardware

El proceso de adquisición de la señal EMG se llevó a cabo mediante un módulo comercial de superficie EGBO, que se basa en la arquitectura Muscle Sensor v3 de Advancer Technologies. Este dispositivo emplea varias etapas de acondicionamiento analógico compuesta por un amplificador de instrumentación referencia AD8226 para la adquisición de señales de baja amplitud con una relación de rechazo en modo común (CMRR) típica de 90 dB con producto ganancia-ancho de banda en torno a 1 MHz ganancia ajustable de 1 a 1.000; luego pasa a una configuración de amplificador operacional (AO) rectificador de onda completa de referencia TL084 de la familia FET; un filtro pasabajos de primer orden con una  $F_c = 1.98$  Hz inversor encargado de reducir el ruido de la señal, después pasa a una etapa de amplificador inversor de ganancia ajustable de 1 a 207.

El TL084, caracterizado por una alta impedancia de entrada, con un CMRR típica de 86 dB y un producto ganancia-ancho de banda en torno a 4 MHz, las cuales son características que propician la adquisición de señales biomédicas de baja amplitud [14].

El acondicionamiento analógico de la señal adquirida se implementó utilizando un filtro paso bajo RC, cuyo comportamiento fue diseñado específicamente para atenuar el ruido de alta frecuencia y resaltar la envolvente de la señal EMG proporcionando información suficientemente representativa para detectar los niveles de contracción en un área muscular específica [15]. La frecuencia de corte del filtro se calculó utilizando la siguiente relación:


$$f_c = \frac{1}{2\pi RC} \quad (1)$$

donde R y C representan la resistencia y la capacitancia del circuito, respectivamente. Para el sistema propuesto se seleccionaron valores de  $R = 56$  k $\Omega$  y  $C = 22$  nF, obteniéndose una frecuencia de corte aproximada de 129 Hz. La selección de este

valor permitió mantener el filtrado analógico dentro del intervalo de frecuencias de interés de las señales electromiográficas superficiales, cuyo contenido espectral útil se encuentra típicamente entre 20 Hz y 500 Hz, reduciendo simultáneamente componentes de ruido de alta frecuencia antes de la digitalización de la señal. Debido a que el módulo EGBO ya incorpora internamente etapas de amplificación y acondicionamiento analógico, el filtro RC implementado en este trabajo actuó como una etapa complementaria previa al proceso de adquisición.

Posteriormente, la señal digitalizada mediante el conversor analógico-digital MCP3008 fue procesada en la Raspberry Pi 4. Adicionalmente, se incorporó un capacitor de desacoplo de 100 nF en la etapa de comparación con el fin de mejorar la estabilidad operativa y reducir la influencia del ruido de alta frecuencia [12].

El diseño electrónico se verificó mediante simulación en Proteus, como se muestra en la Fig 2.




**Fig. 2.** Esquema del circuito de acondicionamiento y clasificación implementado en Proteus.

**Fuente:** elaboración propia.

Se construyó un comparador de ventana utilizando el circuito integrado LM393. Se establecieron dos niveles de referencia con potenciómetros de 10K $\Omega$  configurados como divisores de tensión entre 3,3V y tierra. Los terminales variables de los potenciómetros se conectaron a las entradas de referencia del comparador, estableciendo así el umbral inferior (TH1) y el umbral superior (TH2). La señal sin filtrar se aplicó simultáneamente a ambas entradas del comparador y se evaluó con respecto a los niveles de referencia definidos. Esta configuración permite clasificar la señal en los siguientes estados de activación muscular: reposo, contracción leve y contracción fuerte. Los valores umbral se ajustaron experimentalmente según la amplitud de la señal EMG adquirida. Los rangos

típicos fueron de aproximadamente 0,4V para el reposo, 0,8V para la contracción leve y hasta 1,9V para la contracción fuerte.

Estos rangos proporcionaron una clara separación entre los estados y mejoraron la estabilidad del sistema frente a las variaciones de la señal. La Fig. 3, ilustra la implementación física, que incluye el sensor EMG, la etapa de acondicionamiento de la placa de pruebas, el convertidor MCP3008, la Raspberry Pi 4 y el servomotor.



**Fig. 3** Configuración experimental del sistema propuesto, que muestra los electrodos EMG, el módulo sensor, el circuito de acondicionamiento y comparación basado en el LM393, el convertidor MCP3008, la Raspberry Pi 4 y el servomotor utilizado como actuador.

**Fuente:** elaboración propia.

Se utilizó un convertidor analógico-digital MCP3008 para digitalizar la señal, comunicándose con la Raspberry Pi 4, mediante el protocolo SPI. Es importante destacar que la señal digitalizada se utilizó exclusivamente para monitorización y almacenamiento de datos, mientras que los estados de contracción se clasificaron directamente mediante el comparador analógico. El actuador fue controlado por un servomotor INJORA, accionado por señales PWM generadas por la Raspberry Pi 4. El actuador se seleccionó en función de su capacidad de par nominal, suficiente para demostrar el funcionamiento del sistema en condiciones de laboratorio.

### 2.3. Adquisición y procesamiento de señales

La señal electromiográfica se adquirió utilizando el canal 0 del convertidor analógico-digital MCP3008, configurado con una resolución de 10 bits y una tensión de referencia de 3,3V. Este convertidor se comunica con la Raspberry Pi 4 a través del protocolo SPI, lo que permite la lectura continua de la señal analógica acondicionada.

Una vez digitalizada, la señal fue procesada mediante un filtro pasabanda Butterworth de cuarto

orden implementado por software, con una frecuencia de corte inferior de 20 Hz y una frecuencia de corte superior de 500 Hz. La selección de este intervalo se fundamentó en que el contenido espectral útil de las señales electromiográficas superficiales se encuentra predominantemente entre dichas frecuencias. El filtrado permitió atenuar las componentes de muy baja frecuencia asociadas a artefactos por movimiento y variaciones de la línea base, así como reducir las componentes de alta frecuencia relacionadas con ruido eléctrico e interferencias del sistema de adquisición, mejorando la relación señal-ruido para el análisis de la actividad muscular. Es importante destacar que la señal digitalizada no se utilizó para la toma de decisiones por parte del sistema de control; la clasificación de los niveles de contracción muscular se realizó utilizando un comparador analógico con un LM393 para separar el procesamiento de control de la monitorización de la señal, reduciendo así la carga computacional en la Raspberry Pi 4. La adquisición de datos se realizó a una frecuencia de muestreo aproximada de 50Hz, suficiente para seguir la envolvente de la señal EMG a medida que pasaba por el filtro de paso bajo.

El sistema fue ejecutado utilizando el lenguaje Python, haciendo uso de las librerías spidev para llevar a cabo la comunicación SPI con el MCP3008, GPIO para leer las salidas digitales del comparador LM393 y el control PWM del servomotor, Matplotlib para la representación en tiempo real de la señal adquirida, y se descargan en formato csv para el almacenamiento de los datos experimentales. El MCP3008 fue configurado utilizando el bus SPI 0 y el dispositivo 0, con una velocidad máxima de comunicación de 1,35 MHz. La señal acondicionada que procedía del módulo EMG fue adquirida utilizando el canal CH0 del convertidor y convertida a valores de voltaje en ese instante haciendo uso de una tensión de 3,3 V.

**Tabla 1:** Valores de voltaje obtenidos experimentalmente durante la calibración del sistema, junto con las combinaciones lógicas generadas por el comparador LM393 y su correspondiente clasificación de los estados musculares.

| Voltaje medido experimentalmente con multímetro (V)                | OUT1 (LM393) | OUT2 (LM393) | Estado muscular clasificado                | Descripción                                                                                                                          |
|--------------------------------------------------------------------|--------------|--------------|--------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------|
| $\leq 0,4$ V<br>(Medido experimentalmente con multímetro)          | 1            | 1            | Reposo                                     | Ausencia de activación muscular.                                                                                                     |
| $0,4$ V – $0,8$ V<br>(Medido experimentalmente con multímetro)     | 0            | 1            | Contracción leve                           | Activación muscular moderada.                                                                                                        |
| $0,8$ V – $1,9$ V<br>(Medido experimentalmente con multímetro)     | 0            | 0            | Contracción fuerte                         | Activación muscular máxima.                                                                                                          |
| $> 0,8$ V y $< 1,9$ V<br>(Medido experimentalmente con multímetro) | 1            | 0            | Contracción leve (criterio de estabilidad) | Estado transitorio debido a fluctuaciones de la señal. Se clasifica como contracción leve para garantizar estabilidad en el sistema. |

**Fuente:** elaboración propia.

## 2.4. Control de servomotor

El sistema actuador se diseñó utilizando un servomotor INJORA, controlado por señales de PWM generadas por una Raspberry Pi 4. La señal PWM se configuró con una frecuencia de 50Hz, la frecuencia de operación para este tipo de dispositivo.

Se definieron tres posiciones angulares, correspondientes a los estados de contracción previamente definidos: 0° para el estado de reposo, 45° para la contracción media y 90° para la contracción máxima. Para estabilizar el control y eliminar oscilaciones no deseadas en el actuador, se incluyó un algoritmo de validación temporal. El sistema opera con una frecuencia de muestreo de aproximadamente 50Hz (intervalo de 0,02s), evaluando continuamente las salidas del comparador.

Un cambio de estado solo se aceptará si permanece constante durante cinco muestras consecutivas, lo que implica un tiempo mínimo de validación de aproximadamente 0,1s. Además, se definieron tiempos mínimos de permanencia en cada estado: 0,20s en reposo, 0,30s durante la contracción media y 0,80s cuando se alcanza el valor máximo durante la contracción muscular. Esta estrategia permite diferenciar las variaciones transitorias de la señal (ruido o picos cortos) de una contracción sostenida y reduce significativamente el comportamiento errático del servomotor.

## 2.5. Visualización y almacenamiento de datos


Se creó una aplicación Thonny-Python para adquirir y almacenar la señal electromiográfica en tiempo real. La señal, convertida a formato digital por el MCP3008, se procesa y grafica utilizando la biblioteca Matplotlib, lo que permite la representación gráfica del comportamiento dinámico de la señal bajo diferentes condiciones de contracción muscular. La visualización se muestra en una ventana interactiva, donde la señal se actualiza continuamente en función de las muestras adquiridas, lo que permite identificar patrones derivados de los estados de reposo, contracción media y contracción máxima. Los datos se almacenan en archivos CSV, que contienen información como el tiempo de adquisición, el valor digital del ADC, el voltaje correspondiente, las salidas del comparador (OUT1 y OUT2) y el estado de contracción identificado por el sistema.

## 3. RESULTADOS

La configuración experimental utilizada para validar el sistema se muestra en la Fig. 3, mientras que la implementación a nivel de circuito se detalla en la Fig. 2. Ambas configuraciones nos permitieron verificar el comportamiento del sistema bajo diferentes condiciones de activación muscular durante la etapa de condicionamiento analógico y durante la integración total del sistema de clasificación y control.

### 3.1. Acondicionamiento de la señal EMG


La Fig. 4 presenta la comparación entre la señal EMG adquirida antes y después del acondicionamiento analógico mediante el filtro RC implementado en el sistema. La superposición de ambas señales evidencia que el filtrado reduce las fluctuaciones rápidas y las componentes de alta frecuencia, obteniéndose una envolvente más estable que facilita la identificación de los diferentes niveles de activación muscular. Aunque la amplitud de la señal disminuye ligeramente debido al proceso de suavizado, se conserva la información necesaria para la clasificación de los estados de reposo, contracción leve y contracción fuerte.



**Fig. 4.** Comparación de la señal EMG adquirida antes y después del filtrado físico externo mediante un filtro RC de paso bajo. **Fuente:** elaboración propia.

Con el fin de analizar el efecto del acondicionamiento desde el dominio de la frecuencia, la Fig. 5 muestra la comparación del espectro de la señal EMG antes y después del filtrado combinado, conformado por el filtro RC analógico y un filtro pasabanda Butterworth implementado digitalmente con frecuencias de corte de 20 Hz y 500 Hz. Se observa que el filtrado atenúa las componentes de muy baja frecuencia, asociadas principalmente al desplazamiento de la línea base y artefactos por movimiento, así como las componentes de alta frecuencia relacionadas con ruido eléctrico, preservando la mayor parte del

contenido espectral útil de la señal electromiográfica.




**Fig. 5.** Comparación del espectro de frecuencia de la señal EMG antes y después del proceso de filtrado mediante un filtro RC y un filtro pasabanda Butterworth digital.

**Fuente:** elaboración propia.

Como resultado del proceso de acondicionamiento y filtrado, la señal utilizada por el sistema presenta una respuesta más estable y con una mejor relación señal-ruido, permitiendo una detección más confiable de los niveles de activación muscular. Estas características facilitaron el ajuste experimental de los umbrales empleados por el comparador LM393 para discriminar los tres estados de operación del sistema: reposo, contracción leve y contracción fuerte, utilizados posteriormente para el control del servomotor.

### 3.2. Respuesta del sistema con clasificación mediante LM393

La Fig. 5 muestra la respuesta del sistema al incorporar el comparador de ventana LM393, junto con la arquitectura de control completa, donde la señal no es continua, sino que está representada en niveles discretos que corresponden a los estados de activación muscular definidos por el sistema.



**Fig. 6.** Respuesta del sistema con clasificación del nivel de contracción. **Fuente:** elaboración propia.

A diferencia de la señal obtenida únicamente con filtrado de paso bajo, la salida del sistema presenta

una discretización bien definida en tres niveles claramente diferenciados. Estos niveles corresponden a los estados de reposo, contracción media y contracción máxima, que se identifican en la señal como regiones de baja amplitud, mesetas estables y picos de alta amplitud, respectivamente. Las regiones de reposo se caracterizan por valores bajos y relativamente constantes, indicativos de una inactividad muscular significativa. La contracción media aparece como segmentos tipo meseta, lo que indica una activación muscular sostenida; la contracción máxima se manifiesta como picos de mayor amplitud, asociados a un mayor esfuerzo muscular.

Las transiciones entre estos estados están bien definidas y son consistentes, lo que demuestra la correcta selección de los umbrales de comparación establecidos en el sistema.

### 3.3. Comportamiento del sistema de control

El comportamiento del sistema de control se evaluó en función de la respuesta del servomotor a diferentes estados de activación muscular detectados. El sistema responde de forma consistente a las señales del comparador LM393, con una clara correspondencia entre los estados de reposo, contracción media y contracción máxima, y las posiciones angulares definidas del actuador.

En cuanto a las contracciones sostenidas, la señal clasificada presenta regiones estables tipo meseta. Esta información permite guiar de manera adecuada la respuesta del servomotor sin oscilaciones perceptibles. Si la señal EMG presenta variaciones rápidas o picos transitorios, la salida no se verá alterada. En general, el sistema de control demuestra respuestas estables a los cambios en la activación muscular, lo que permite transiciones bien definidas entre estados sin fluctuaciones indeseadas en el actuador.

## 4. DISCUSIÓN

Los resultados obtenidos confirman la operatividad y funcionalidad del sistema de control mioeléctrico diseñado. La arquitectura híbrida basada en acondicionamiento analógico, filtrado digital y clasificación por lógica discreta permitió discriminar experimentalmente los estados de reposo, contracción leve y contracción fuerte, logrando un accionamiento estable del servomotor sin oscilaciones significativas. Estos hallazgos validan la propuesta como una alternativa viable y de bajo costo para el desarrollo de prótesis

mioeléctricas y plataformas de experimentación [16], [17].

En años recientes, el reconocimiento de patrones sEMG ha migrado hacia técnicas de aprendizaje automático (machine learning) y aprendizaje profundo (deep learning), las cuales combinan información multicanal para discriminar gestos y movimientos con mayor precisión [17], [18]. Diversas investigaciones emplean algoritmos avanzados de extracción de características y clasificadores como máquinas de vectores de soporte (SVM) o redes neuronales artificiales, alcanzando altas tasas de exactitud en tareas complejas [19], [20]. No obstante, aunque estas alternativas representan un avance sustancial, demandan elevada capacidad de cómputo, así como fases rigurosas de entrenamiento con bases de datos anotadas y calibración individualizada [21], [22]. Esto incrementa la complejidad algorítmica y limita su implementación directa en sistemas embebidos de recursos restringidos [23], [24], [25].

Desde la perspectiva del diseño, la arquitectura propuesta ofrece ventajas sustanciales frente a enfoques más complejos. La integración de componentes comerciales accesibles (sensor EMG EGBO, conversor MCP3008 y Raspberry Pi 4) dio lugar a una plataforma modular, reproducible y escalable. Al delegar la clasificación primaria al comparador analógico, el procesamiento digital se concentró en el acondicionamiento y almacenamiento de la señal, optimizando el uso de recursos computacionales sin comprometer la estabilidad durante las pruebas. Esta estrategia resulta especialmente eficiente cuando solo se requiere discriminar un número reducido de estados musculares.

A pesar de estas fortalezas, el sistema presenta limitaciones inherentes a su naturaleza discreta. La dependencia de umbrales fijos mediante potenciómetros ajustables expone la clasificación a variaciones fisiológicas interindividuales, fatiga muscular o desplazamientos en la posición de los electrodos. Asimismo, el alcance del método se reduce a tres niveles de activación, a diferencia de los modelos basados en inteligencia artificial que reconocen un abanico más amplio de gestos y se adaptan mejor a condiciones dinámicas [17], [19].

Sin embargo, el diseño desacoplado entre las etapas de adquisición, acondicionamiento y procesamiento constituye una base sólida para futuras mejoras. Esta arquitectura modular permite integrar progresivamente algoritmos de reconocimiento de

patrones o modelos de IA sin alterar el hardware de captura. De este modo, la clasificación por lógica discreta puede evolucionar hacia esquemas de aprendizaje automático que amplíen el número de grados de libertad reconocidos, preservando la misma infraestructura electrónica.

En síntesis, la combinación de acondicionamiento analógico y clasificación discreta representa una solución eficiente en consumo computacional, estable y accesible para aplicaciones de control mioeléctrico. Si bien no busca sustituir a los sistemas clínicos avanzados basados en inteligencia artificial, sí consolida una plataforma flexible y escalable para prototipado en entornos educativos y de investigación.

## 5. CONCLUSIONES

Se diseñó e implementó un sistema de adquisición y control de señales sEMG de bajo costo para prótesis mioeléctricas. La plataforma adquiere, acondiciona y clasifica la señal EMG en tres estados discretos de contracción muscular mediante un procesador Raspberry Pi 4, el cual comanda un actuador a través de señales PWM.

La combinación de un filtro paso bajo RC con un comparador de ventana (LM393) demostró que es posible identificar con precisión los niveles de activación muscular sin recurrir a un procesamiento digital complejo. Asimismo, la estrategia de validación temporal integrada en el algoritmo de control mitiga las oscilaciones asociadas a la naturaleza no estacionaria de la señal sEMG, garantizando una respuesta estable y consistente del actuador.

El principal aporte de este trabajo reside en la arquitectura híbrida (analógica-digital), la cual reduce significativamente la carga computacional y optimiza el desempeño en sistemas embebidos. Este enfoque valida la viabilidad de implementar esquemas de control mioeléctrico funcionales, estables y accesibles para aplicaciones de rehabilitación básicas.

**Contribuciones de los autores:** Yeison Manuel Arias Nuñez: Redacción – revisión y edición, redacción – borrador original, visualización, creación de prototipos, análisis de resultados, conceptualización. Sandra Patricia Usaquen-Perilla: Redacción – revisión y edición, validación, conceptualización. Mauricio Alejandro Gómez-Figueroa: Redacción – revisión y edición, asesor

metodológico, creación de prototipos, validación, conceptualización.

**Financiación:** Los autores y el semillero de investigación Innova-GIoT<sup>TM</sup> proporcionaron la financiación.

**Agradecimientos:** Este trabajo es producto del semillero de investigación Innova-GIoT<sup>TM</sup> de la Universidad Militar Nueva Granada.

## REFERENCIAS

- [1] M. S. Hossain, M. J. Islam, and M. R. Islam, "Unraveling cemg-wet semg correlation dynamics: In- vestigating influential factors," *Journal of Electromyography and Kinesiology*, vol. 78, p. 102912, 2024, doi:10.1016/j.jelekin.2024.102912.
- [2] G. Balbinot, M. J. Wiest, G. Li, M. Pakosh, J. C. Furlan, S. Kalsi-Ryan, and J. Zariffa, "The use of surface emg in neurorehabilitation following traumatic spinal cord injury: A scoping review," *Clinical Neurophysiology*, vol. 138, pp. 61–73, 2022, doi:10.1016/j.clinph.2022.02.028.
- [3] F. Davarinia and A. Maleki, "Automated estimation of clinical parameters by recurrence quantification analysis of surface emg for agonist-antagonist muscles in amputees," *Biomedical Signal Processing and Control*, vol. 68, p. 102740, 2021, doi:10.1016/j.bspc.2021.102740.
- [4] L.-I. Hsu, K.-W. Lim, Y.-H. Lai, Y.-L. Lin, Y.-J. Chen, C.-S. Chen, and L.-W. Chou, "Turns- amplitude and power spectral analyses of surface emg for assessing muscle fatigue and recovery during dynamic hand gripping," *Computers in Biology and Medicine*, vol. 193, p. 110430, 2025, doi:10.1016/j.combiomed.2025.110430.
- [5] E. R. Avila, S. E. Williams, and C. Disselhorst-Klug, "Advances in emg measurement techniques, analysis procedures, and the impact of muscle mechanics on future requirements," *Journal of Biomechanics*, vol. 156, p. 111687, 2023, doi:10.1016/j.jbiomech.2023.111687.
- [6] Z. Taghizadeh, S. Rashidi, and A. Shalbah, "Finger movements classification based on fractional fourier transform coefficients extracted from surface emg signals," *Biomedical Signal Processing and Control*, vol. 68, p. 102573, 2021, doi:10.1016/j.bspc.2021.102573.
- [7] T. Mahboob, M. Y. Chung, and K. W. Choi, "Emg-based 3d hand gesture prediction using transformer encoder classification," *ICT Express*, vol. 9, pp. 1047–1052, 2023, doi:10.1016/j.icte.2023.04.005.
- [8] M. J. Karim, A. Khandakar, K. Thomas, A. Rahman, M. F. Ahamed, P. N. Suganthan, and M. A. Ayari, "Emg-based prosthetics control using explainable ai on edge devices," *Biomimetic Intelligence and Robotics*, p. 100307, 2026, doi:10.1016/j.birob.2026.100307.
- [9] P. Baraneedharan, S. Kalaivani, S. Vaishnavi, and K. Somasundaram, "Revolutionizing healthcare: Rasp- berry pi-powered health monitoring sensors," *Computers in Biology and Medicine*, vol. 190, p. 110109, 2025, doi:10.1016/j.combiomed.2025.110109.
- [10] P. Tsakonas, N. D. Evans, J. Hardwicke, and M. J. Chappell, "A novel pipeline for converting surface electromyography signals into muscle activations," *Biomedical Signal Processing and Control*, vol. 102, p. 100204, 2026, doi:10.1016/j.bspc.2025.100204.
- [11] S. A. Khomami and S. Shamekhi, "Persian sign language recognition using imu and surface emg sensors," *Measurement*, vol. 168, p. 108471, 2021, doi:10.1016/j.measurement.2020.108471.
- [12] T. Ganokratana, M. Ketcham, and P. Pramkeaw, "A practical muscle-signal-driven control mechanism for an affordable robotic prosthetic hand," *Engineering Applications of Artificial Intelligence*, vol. 167, p. 113833, 2026, doi:10.1016/j.engappai.2026.113833.
- [13] T. Sharma, K. P. Sharma, and K. Veer, "Decomposition and evaluation of semg for hand prostheses control," *Measurement*, vol. 186, p. 110102, 2022, doi:10.1016/j.measurement.2021.110102.
- [14] Advancer Technologies, "Muscle Sensor v3 User Manual: Three-lead Differential Muscle/Electromyography Sensor for Microcontroller Applications," Advancer Technologies, User Manual, Feb. 2013.
- [15] Y. A. Jarrah, M. G. Asogbon, O. W. Samuel, X. Wang, M. Zhu, E. Nsugbe, S. Chen, and G. Li, "High- density surface emg signal quality enhancement," *Biomedical Signal Processing and Control*, vol. 68, p. 102573, 2021, doi:10.1016/j.bspc.2021.102573.

- Control*, vol. 74, p. 103497, 2022, doi:10.1016/j.bspc.2022.103497.
- [16] S. Ni, M. A. A. Al-qaness, A. Hawbani, D. Al-Alimi, M. Abd Elaziz, and A. A. Ewees, "A survey on hand gesture recognition based on surface electromyography," *Applied Soft Computing*, vol. 166, p. 112235, 2024, doi:10.1016/j.asoc.2024.112235.
- [17] S. M. Sid'El Moctar, I. Rida, and S. Boudaoud, "Feature extraction techniques for semg classification," *IRBM*, vol. 45, p. 100866, 2024, doi:10.1016/j.irbm.2024.100866.
- [18] L. Wang, J. Fu, H. Chen, and B. Zheng, "Hand gesture recognition using emg and accelerometer," *Biomedical Signal Processing and Control*, vol. 86, p. 105141, 2023, doi:10.1016/j.bspc.2023.105141.
- [19] W. N. Abdelrazik, A. El-Bialy, H. A. Ibrahim, and B. A. Hemade, "Emg-based gesture recognition with dimensionality reduction," *Sensors and Actuators A: Physical*, vol. 396, p. 117120, 2025, doi:10.1016/j.sna.2025.117120.
- [20] V. Mejía Gallón, S. Madrid Vélez, J. Ramírez, and F. Bolaños, "Comparison of machine learning algorithms for emg activation timing," *Biomedical Signal Processing and Control*, vol. 94, p. 106266, 2024, doi:10.1016/j.bspc.2024.106266.
- [21] R. Q. Fuentes-Aguilar, D. Llorente-Vidrio, L. Campos-Macias, and E. Morales-Vargas, "Surface electromyography dataset from hand movements," *Data in Brief*, vol. 57, p. 111079, 2024, doi:10.1016/j.dib.2024.111079.
- [22] F. Reyes-Jiménez, F. Rosas-Agraz, E. Macias-Naranjo, F. Alvarado-Rodríguez, H. Vélez-Pérez, R. Romo-Vázquez, and E. Guzmán-Quezada, "Eeg and emg dataset for movement-related potentials," *Data in Brief*, vol. 65, p. 112596, 2026, doi:10.1016/j.dib.2026.112596.
- [23] M. Shankar and M. Tamilarasi, "Hand gesture classification using deep learning," *Journal of the Chinese Institute of Engineers*, vol. 49, no. 2, pp. 374–390, 2026, doi:10.1080/02533839.2025.2538513.
- [24] L. Lin, Y. Dai, G. Zhang, Y. Ge, A. M. Mayet, X. Pan, G. Yang, and M. Lin, "Low-computational emg gesture recognition for prosthetic control," *Results in Engineering*, vol. 27, p. 106602, 2025, doi:10.1016/j.rineng.2025.106602.
- [25] X. Li, L. Tian, Y. Zheng, O. W. Samuel, P. Fang, L. Wang, and G. Li, "Feature filtering technique for myoelectric prostheses," *Biomedical Signal Processing and Control*, vol. 70, p. 102969, 2021, doi:10.1016/j.bspc.2021.102969.
- [26] X. Li, Y. Liu, X. Zhou, Z. Yang, L. Tian, P. Fang, and G. Li, "Simultaneous motion recognition and force estimation," *Biomedical Signal Processing and Control*, vol. 85, p. 105044, 2023, doi:10.1016/j.bspc.2023.105044.
- [27] J. Li, Z. Zhu, W. J. Boyd, C. Martinez-Luna, C. Dai, H. Wang, H. Wang, X. Huang, T. R. Farrell, and E. A. Clancy, "Virtual regression-based myoelectric control," *Biomedical Signal Processing and Control*, vol. 82, p. 104602, 2023, doi:10.1016/j.bspc.2023.104602.
- [28] A. Leccia, M. Sallam, S. Grazioso, T. Caporaso, G. Di Gironimo, and F. Ficuciello, "Virtual simulator for myoelectric prosthesis prototype," *Engineering Applications of Artificial Intelligence*, vol. 121, p. 105853, 2023, doi:10.1016/j.engappai.2023.105853.
- [29] F. Shabbir, M. Iqbal, A. Asghar, S. Khan, and S. J. Khan, "Six-degree-of-freedom prosthetic hand with emg control," *Engineering Applications of Artificial Intelligence*, vol. 142, p. 109949, 2025, doi:10.1016/j.engappai.2024.109949.
- [30] N. N. Unanyan and A. A. Belov, "Upper limb prosthesis design using emg," *Biomedical Signal Processing and Control*, vol. 70, p. 103062, 2021, doi:10.1016/j.bspc.2021.103062.
- [31] S. E. Mathe, H. K. Kondaveeti, S. Vappangi, S. D. Vanambathina, and N. K. Kumaravelu, "A comprehensive review on applications of raspberry pi," *Computer Science Review*, vol. 52, p. 100636, 2024, doi:10.1016/j.cosrev.2024.100636.