

Reconocimiento automático de gestos de la mano a partir de señales de electromiografía de superficie multicanal mediante modelos de ML y DL

Automated hand gesture recognition from multichannel surface electromyography signals through ML and DL models

SARA VALENTINA HERNÁNDEZ SALAZAR¹ - JAVIER ALBERTO CHAPARRO PRECIADO²
JENNY CAROLINA CASTIBLANCO SÁNCHEZ³

1. Estudiante de maestría en Ingeniería Electrónica, Universidad Escuela Colombiana de Ingeniería Julio Garavito, DOI 0009-0006-6270-2536.

2. Ph.D. en Ingeniería Biomédica, Universidad Escuela Colombiana de Ingeniería Julio Garavito, DOI 0000-0001-7078-3213.

3. Ph.D. en Ingeniería, Universidad Escuela Colombiana de Ingeniería Julio Garavito, DOI 0000-0001-7224-2664.

sara.hernandez@mail.escuelaing.edu.co - javier.chaparro@escuelaing.edu.co -
jenny.castiblanco@escuelaing.edu.co

Recibido: 20/02/2025 Aceptado: 31/03/2025

Disponible en http://www.escuelaing.edu.co/es/publicaciones_revista
<http://revistas.escuelaing.edu.co/index.php/reci>

Resumen

El reconocimiento de gestos de la mano (HGR, por su sigla en inglés) a partir de señales de electromiografía de superficie (sEMG) se ha consolidado como una línea de investigación de gran interés en los ámbitos biomédico y tecnológico, debido a su potencial aplicación en prótesis, rehabilitación y control de dispositivos inteligentes. El objetivo de esta revisión es analizar los avances recientes y los retos técnicos asociados al HGR, considerando el flujo típico de estos sistemas: adquisición de datos, preprocesamiento, extracción de características y clasificación. Se abordan técnicas tradicionales de machine learning (ML) como máquinas de soporte vectorial (SVM), K-vecinos cercanos (KNN) y random forest, así como enfoques de deep learning (DL), entre estos redes neuronales convolucionales (CNN) y modelos híbridos. Igualmente, se discuten los principales desafíos del área, entre los cuales se destacan la variabilidad intersujeto, la falta de bases de datos etiquetadas y la robustez de los modelos en entornos reales. Esta revisión contribuye a identificar vacíos de investigación y orientaciones

futuras para el desarrollo de sistemas de HGR más robustos, accesibles y generalizables.

Palabras claves: electromiografía de superficie, reconocimiento de gestos de la mano, machine learning, deep learning.

Abstract

Hand gesture recognition (HGR) based on surface electromyography (sEMG) signals has established itself as a line of research of great interest in the biomedical and technological fields, due to its potential application in prosthetics, rehabilitation, and the control of smart devices. This review analyzes recent advances and technical challenges associated with HGR, considering the typical flow of HGR systems: data acquisition, preprocessing, feature extraction, and classification. Traditional machine learning (ML) techniques such as Support Vector Machine (SVM), k-nearest neighbors (KNN), and Random Forests are addressed, as well as deep learning (DL) approaches, including Convolutional Neural Network (CNN) and hybrid models. It also discusses

the main challenges in the field, including inter-subject variability, the lack of labeled databases, and the robustness of models in real-world environments. This review identifies research gaps and future directions for developing more robust, accessible, and generalizable HGR systems.

Keywords: surface electromyography; hand gesture recognition; machine learning; deep learning.

INTRODUCCIÓN

Las tecnologías de asistencia, como prótesis, sillas de ruedas, robots de asistencia social y exoesqueletos, se han desarrollado para mejorar la funcionalidad motora de personas con discapacidad (Hu et al., 2018). Estas soluciones no solo han revolucionado la manera en que las personas con limitaciones motoras interactúan con su entorno, sino que les ha permitido recuperar funciones esenciales y participar activamente en sus actividades diarias (Carver et al., 2015). En este contexto, uno de los principales retos en el campo de las tecnologías asistivas es lograr una comunicación eficaz entre el usuario y el dispositivo, lo que ha impulsado el desarrollo de sistemas de reconocimiento de gestos de la mano (HGR, por su sigla en inglés) basados en señales de electromiografía de superficie (sEMG), cuyo objetivo es traducir la actividad muscular en comandos de control intuitivos (Mohamed et al., 2021).

La mano humana es un foco de interés en el reconocimiento de gestos debido a su complejidad anatómica y su capacidad para ejecutar movimientos finos y precisos (Guo et al., 2021). A diferencia de otros métodos de grabación de movimiento, las señales sEMG ofrecen una opción no invasiva para captar la intención motora del usuario (Jaramillo-Yáñez et al., 2020). De esta manera, los sistemas HGR permiten interpretar y clasificar movimientos estáticos o dinámicos de las manos a partir de datos eléctricos generados por la actividad muscular, pero no solo buscan replicar los movimientos de la extremidad en aplicaciones protésicas, sino que también tienen aplicaciones en rehabilitación, control de dispositivos inteligentes y realidad aumentada (Jiang et al., 2022). En este sentido, el reconocimiento automático de gestos de la mano ha cobrado gran relevancia en los últimos años debido a su potencial impacto en la interacción hombre-máquina y en el desarrollo de tecnologías de asistencia más intuitivas y eficientes (Li et al., 2021).

Entre las técnicas utilizadas para la clasificación de gestos, la sEMG se destaca por su naturaleza no inva-

siva y su capacidad para registrar las señales eléctricas generadas por la actividad muscular en la piel (Li et al., 2021). Sin embargo, a pesar de su potencial, la implementación de sistemas de HGR basados en sEMG precisos, robustos y generalizables sigue representando desafíos técnicos y científicos, debido a factores como la alta dimensionalidad de las señales, la variabilidad entre usuarios y la necesidad de mejorar la estabilidad de los modelos ante diferentes condiciones de uso (Jochumsen et al., 2018).

La bibliografía previa evidencia limitaciones en la disponibilidad de bases de datos grandes y estandarizadas, la falta de consenso en los protocolos experimentales y la escasa generalización de los modelos en escenarios reales, no solamente con sujetos sanos sino con sujetos en condición de discapacidad, lo que revela vacíos importantes que se busca analizar en esta revisión.

En consecuencia, el presente artículo tiene como propósito revisar y organizar los avances recientes en el reconocimiento de gestos de la mano basado en señales sEMG, mediante la identificación de los principales enfoques, desafíos y tendencias actuales. Este artículo de revisión se estructura en cuatro secciones: en la primera se describe la metodología de búsqueda, en la segunda se presenta el estado del arte, en la tercera se discuten los principales hallazgos, y en la última se exponen las conclusiones y líneas futuras.

METODOLOGÍA

En la construcción de este artículo de revisión se siguió un enfoque sistemático. En primera instancia, se consultaron bases de datos indexadas y reconocidas a escala internacional, tales como Scopus, IEEE Xplore, ScienceDirect, SpringerLink y PubMed.

La búsqueda se realizó empleando un conjunto de palabras claves en inglés, tales como *surface electromyography*, *hand gesture recognition*, *machine learning* y *deep learning*. Estas palabras se combinaron mediante operadores booleanos (AND, OR) con el objetivo de ampliar o restringir los resultados según cada necesidad de análisis.

El rango temporal definido para la búsqueda fue 2019 a 2025 y la consulta se hizo entre octubre de 2024 y febrero de 2025, seleccionando únicamente artículos publicados en inglés en revistas indexadas o conferencias internacionales.

Posteriormente, se establecieron criterios de inclusión y exclusión. Los criterios de inclusión abarcaron estudios que:

- Presentaran desarrollos metodológicos en la adquisición, preprocesamiento, extracción de características y clasificación de señales sEMG.
- Evaluaran el desempeño de algoritmos de *machine learning* y *deep learning* en tareas de reconocimiento de gestos de la mano.
- Reportaran métricas de rendimiento (precisión, exactitud, sensibilidad, especificidad, *F1-score*, entre otras).
- Artículos de revisión que aportaran un análisis global del estado del arte en el reconocimiento de gestos mediante señales de sEMG.

Por otro lado, se excluyeron los estudios que no cumplieran con los lineamientos metodológicos establecidos, específicamente aquellos que:

- Emplearon modalidades distintas de la sEMG, como visión por computador, sensores inerciales o dispositivos ópticos.
- Se enfocaron en reconocimiento de gestos faciales o corporales, no en gestos de la mano.
- No reportaron métricas de desempeño cuantitativas (precisión, exactitud, sensibilidad, *F1-score*, etc.).
- Mostraron información incompleta o inaccesible (sin texto completo o sin datos relevantes).
- Fueron duplicados o versiones preliminares, sin revisión por pares.
- No abordaron el reconocimiento de gestos en humanos (por ejemplo, estudios en simulaciones o prótesis robóticas sin señales biológicas reales).

A continuación se presenta el diagrama de flujo Prisma, que ilustra el proceso de identificación, selección y exclusión de los estudios considerados en esta revisión (figura 1). A partir de la búsqueda inicial en las bases de datos seleccionadas, se identificó un conjunto de 77 artículos, los cuales se sometieron a un proceso de filtrado mediante los criterios de inclusión y exclusión previamente descritos. Finalmente, se seleccionaron 37 artículos que cumplieron con todos los requisitos metodológicos y temáticos establecidos para el análisis detallado.




Figura 1. Diagrama Prisma para la selección de artículos.

REVISIÓN DE LA BIBLIOGRAFÍA (ESTADO DEL ARTE)

Electromiografía de superficie

La electromiografía (EMG) se refiere a la señal eléctrica colectiva de los músculos, controlada por el sistema nervioso y producida durante la contracción muscular. Esta señal representa las propiedades anatómicas y fisiológicas de los músculos, ya que refleja la actividad eléctrica de las unidades motoras de un músculo (Chowdhury et al., 2013). Dentro de la EMG, la electromiografía de superficie (sEMG) es una técnica utilizada para registrar esta actividad eléctrica mediante sensores colocados sobre la piel (Gómez-Correa et al., 2023). La señal de sEMG se genera a partir de la interacción entre las fibras musculares y las neuronas motoras. En estado de reposo, los músculos presentan un potencial eléctrico aproximado de -80 mV (Weiss et al., 2015).

Sin embargo, cuando se produce una contracción muscular, se generan diferencias de potencial dentro de una unidad motora (MU), que está compuesta por un grupo de fibras musculares y una neurona motora. Estas diferencias de potencial surgen cuando la neurona motora activa la unión neuromuscular, enviando señales en direcciones opuestas a través de las fibras musculares. Como resultado, la actividad eléctrica registrada por los

sensores de sEMG es la suma lineal de múltiples trenes de potenciales de acción de la unidad motora (MUAP) (Jaramillo-Yáñez et al., 2020).

Las contracciones musculares se pueden clasificar en dos clases: estáticas y dinámicas (Rani et al., 2023). En una contracción estática, las fibras musculares generan fuerza sin cambiar su longitud y sin movimiento articular. Un ejemplo de este tipo de contracción es cuando una persona mantiene la mano quieta o forma una señal de paz. En contraste, una contracción dinámica implica cambios en la longitud de las fibras musculares y movimiento en las articulaciones, como cuando alguien saluda con la mano. Estas diferencias en la naturaleza de la contracción influyen en la forma en que se registran y analizan las señales de sEMG, puesto que la actividad eléctrica varía en función del tipo de movimiento y la intensidad de la contracción muscular (Chowdhury et al., 2013).

El análisis de las señales de sEMG permite extraer características claves que ayudan a interpretar la actividad muscular. Entre estas características se encuentran el tiempo de activación, que proporciona información sobre la coordinación de los músculos durante un movimiento; la amplitud, que refleja la intensidad de la contracción muscular, y la frecuencia, cuyo análisis puede revelar signos de fatiga, temblores o trastornos neuromusculares (Zheng et al., 2022).

A pesar de sus ventajas como técnica no invasiva y de alta precisión, la adquisición de señales de sEMG se puede ver afectada por varios factores, como el método de recolección, la colocación de los electrodos y el tipo de material utilizado. Generalmente, los electrodos de sEMG se pueden disponer en configuraciones unipolares o bipolares (Stegeman y Hermens, 2007). En el caso de los electrodos unipolares, se requiere solo un sensor para registrar la señal, lo que simplifica su uso y reduce su tamaño. Por otro lado, los electrodos bipolares consisten en un par de electrodos colocados a lo largo de la dirección de las fibras musculares, lo que permite hacer una medición más precisa al minimizar el ruido y mejorar la calidad de la señal captada.

El procesamiento de las señales de sEMG es fundamental para su aplicación en diversas áreas. La adquisición de la señal puede estar contaminada por ruido proveniente del entorno, la actividad fisiológica del sujeto o el propio sistema de medición. Para mitigar estos efectos, se utilizan técnicas de preprocesamiento

que incluyen el uso de filtros específicos para eliminar interferencias y mejorar la calidad de los datos (Ni et al., 2024).

En cuanto a aplicaciones, el uso de sEMG en interfaces de rehabilitación ha permitido desarrollar sistemas que interpretan los movimientos musculares para controlar dispositivos electrónicos, mejorar la funcionalidad de prótesis y facilitar la interacción con tecnologías asistivas. Además, las señales de sEMG se han empleado en el ámbito del aprendizaje automático para diseñar modelos de reconocimiento de gestos con alta precisión, lo que abre nuevas posibilidades en aplicaciones como la realidad virtual, el control de robots y la navegación en entornos digitales (Sultana et al., 2023).

Durante décadas, la señal de sEMG se ha utilizado para predecir la intención motora del miembro superior (Li et al., 2021); por ejemplo, se ha empleado para controlar elementos como prótesis de mano, debido a que las señales sEMG registradas en músculos específicos están asociadas a los gestos de la mano y se pueden usar para controlar diversos movimientos (Lee et al., 2022).

Reconocimiento de gestos de la mano basados en sEMG

El reconocimiento de gestos de la mano (HGR) es una subárea de la visión por computador cuyo objetivo es clasificar un video, una imagen o una señal que contenga un gesto de la mano dinámico o estático (Köpüklü et al., 2019). Esta tecnología tiene una amplia gama de aplicaciones en ingeniería y dispositivos inteligentes (Kuo y Zhang, 2019).

El marco tradicional de reconocimiento de gestos basado en sEMG consta del preprocesamiento de los datos, extracción de características, selección de características y clasificación de gestos; entre estos, la extracción de características y la clasificación de gestos son dos etapas importantes (Hu et al., 2018). Por tal motivo, los investigadores se han centrado en presentar conjuntos de características en el dominio del tiempo o dominio de la frecuencia (Khushaba, 2020), así como en emplear algoritmos convencionales de *machine learning* (ML) para clasificar los gestos de la mano (Samadani y Kulic, 2014; Jaramillo-Yáñez et al., 2020). No obstante, aunque las técnicas de reconocimiento de patrones se han aplicado a la investigación de sEMG durante décadas, el *deep learning* (DL) solamente se ha aplicado en los últimos años (Li et al., 2021).




Figura 2. Diagrama de flujo para modelos de HGR.

La estructura para los modelos HGR puede variar de acuerdo con la bibliografía; sin embargo, los pasos recurrentes se explican a continuación (figura 2).

Recopilación de datos

Actualmente, la adquisición de señales de sEMG se puede hacer mediante una variedad de sensores comerciales y de desarrollo propio. Entre los dispositivos más utilizados se encuentran sistemas de alta precisión como Delsys y Telemyo, que, aun cuando son de alto costo, ofrecen características avanzadas, como la reducción de ruido y la detección de señales de múltiples canales, mientras que soluciones más accesibles, como MyoWare, que se consideran de bajo costo, permiten aplicaciones en entornos menos controlados. Cada uno de estos dispositivos opera con diferentes frecuencias de muestreo, que pueden oscilar entre 200 y 1200 Hz, dependiendo de la aplicación y de los requisitos de procesamiento de señal.

Por otro lado, existen diversas bases de datos de sEMG de libre acceso que se han usado ampliamente para el reconocimiento de gestos de la mano. Una de las más destacadas es la quinta base de datos Nii-Naprop, la cual recopila señales de diez sujetos sanos empleando dos brazaletes Thalmic Myoarmband. Este conjunto de datos se caracteriza por un protocolo experimental riguroso que abarca seis repeticiones de 52 movimientos (además de la posición de descanso), los cuales se han seleccionado tanto a partir de la taxonomía de la mano como de estudios previos en el campo de la robótica y la neurorrehabilitación (Pizzolato et al., 2017).

En cuanto al desarrollo de sistemas HGR, estos se pueden clasificar en dos enfoques principales: sistemas

individuales y sistemas generales. Los primeros están diseñados para reconocer gestos a partir de señales de un solo usuario, lo que puede optimizar el rendimiento del modelo al adaptarse a las características musculares específicas de la persona. Sin embargo, estos sistemas presentan una limitación significativa en cuanto a su generalización, ya que no suelen funcionar de manera óptima cuando se aplican a nuevos usuarios; en contraste, los sistemas generales buscan entrenar modelos con datos provenientes de múltiples individuos, lo que permite una mayor robustez y aplicabilidad en diferentes escenarios. No obstante, dicho enfoque enfrenta desafíos como la variabilidad intersujeto, la necesidad de normalización de las señales y la implementación de técnicas avanzadas de procesamiento para mejorar la capacidad de generalización del modelo (Jaramillo-Yáñez et al., 2020).

Preprocesamiento

Una vez adquiridas las señales se procede con el preprocesamiento de los datos, el cual se hace para obtener datos útiles a partir de las señales de entrada (Ma et al., 2020). Esto es necesario debido a que la señal de sEMG puede ser influida por diversos factores ambientales, la fatiga muscular, la mala colocación de los electrodos, entre otros. Para evaluar la calidad de las señales, se utiliza comúnmente la relación señal a ruido (SNR, por su sigla en inglés), que permite cuantificar la información útil que contiene la señal en comparación con el ruido presente en el sistema de medición. Se ha determinado que se requiere un SNR mínimo de 3:1 para obtener un rendimiento confiable en la descomposición de señales sEMG y en la identificación de unidades motoras (Zaheer et al., 2012).

Así mismo, una señal de sEMG con un bajo nivel de artefactos motores, producto del buen acoplamiento de los electrodos, presentaría un SNR mayor de 50 dB, mientras que una señal con un alto nivel de ruido tendría un SNR inferior a 15 dB (Sinderby et al., 1995).

Antes del reconocimiento del movimiento, se suelen emplear diversas etapas de preprocesamiento, entre las cuales se incluyen el suavizado, la normalización y la segmentación (Li et al., 2021). Sin embargo, la selección de estas etapas no es uniforme, ya que cada investigador decide cuáles incluir o excluir.

- **Suavizado:** Se realiza por medio de la rectificación y el filtrado de la señal. Para la rectificación, los métodos más utilizados en el procesamiento de señales sEMG son la rectificación de onda completa (*full-wave*) y la rectificación de media onda (*half-wave*). Mientras que la rectificación de onda completa convierte todos los valores negativos a positivos, preservando la energía de la señal, la rectificación de media onda simplemente descarta los valores negativos. Se recomienda el uso de la rectificación de onda completa, puesto que permite conservar la energía de la señal y facilita su posterior análisis (Rani et al., 2023).

Por otro lado, según el teorema de muestreo de Nyquist-Hannon, dado que aproximadamente el 95 % de la señal sEMG se encuentra concentrado en el rango de 400-500 Hz, la frecuencia de muestreo del sensor debe ser al menos el doble de la frecuencia más alta del sEMG para evitar *aliasing* y garantizar una adecuada reconstrucción de la señal. En este contexto, los filtros más comúnmente empleados incluyen filtros pasabanda en los rangos de 20-500 Hz, 10-500 Hz y 10-450 Hz, así como filtros *notch* de 50-60 Hz para eliminar interferencias de la red eléctrica (Benalcázar et al., 2017).

- **Normalización:** Las señales sEMG entre sujetos y entre sesiones presentan diferencias, para lo cual es necesario normalizar los datos. Se normaliza una señal cuando se quiere comparar con otras señales, y de este modo se escalan las señales a un nivel idéntico (Burden, 2010). Existen diversas formas de normalización, pero entre las más comunes se encuentran la normalización Min-Max (Zhang et al., 2022), que ajusta los valores a un rango específico, y la normalización Z-score (Chen et al., 2021),

que estandariza los datos en función de su media y desviación estándar.

- **Segmentación:** La segmentación consiste en detectar el gesto, es decir, la porción de la señal en la que se genera la actividad muscular, removiendo la porción donde los músculos se encuentran en reposo. Para ello, se emplea un enfoque de segmentación basado en ventanas, el cual consta de dos partes: ventanas deslizantes y ventanas solapadas. La segmentación de la señal no solo permite aislar la actividad muscular relevante, sino que también puede mejorar la precisión del clasificador, especialmente cuando se adquieren nuevos datos (Nielsen et al., 2011).

Extracción de características

Una vez realizado el preprocesamiento se continúa con la extracción de características. El objetivo de esta etapa es mejorar la diferencia entre los gestos, por lo que es una de las etapas más importantes del proceso. En ella se selecciona un conjunto de características informativas de la señal de sEMG, ya sea en el dominio del tiempo (TD), el dominio de la frecuencia (FD) o la combinación de ambos, esto es, el dominio tiempo-frecuencia (TDF) (Li et al., 2021). Las características en el dominio del tiempo de la señal sEMG se basan en indicadores estadísticos y tratan la señal como una función del tiempo, características que se calculan directamente a partir de la señal sEMG (Rani et al., 2023). En comparación con otras características del sEMG, tienen una baja complejidad computacional y se han utilizado ampliamente; entre las más conocidas se encuentran *Mean Absolute Value* (MAV), *Root Mean Square* (RMS), *Waveform Length* (WL) y *Zero Crossings* (ZC) (Li et al., 2021).

Tras expresar la señal en el dominio del tiempo y transformarla al dominio de la frecuencia mediante la transformada de Fourier, es posible analizar sus características espectrales (Rani et al., 2023). El uso de características en el dominio de la frecuencia presenta ventajas significativas, ya que facilita la extracción de atributos más consistentes y ofrece una mayor resistencia al ruido; entre las más utilizadas se encuentran el espectro de amplitud (*Amplitude Spectrum*, AmpSpec), la frecuencia media (*Mean Frequency*, MNF), la frecuencia mediana (*Median Frequency*, MDF) y la frecuencia mediana modificada (*Modified Median Frequency*, MMDF) (Rani et al., 2023). Las características TFD se expresan como

la ubicación de la energía de la señal sEMG tanto en tiempo como en frecuencia, lo que suele ser un enfoque importante en la extracción de características; entre las más conocidas están la transformada wavelet discreta (DWT), la transformada wavelet continua (CWT) y la media de los coeficientes wavelet absolutos (MOAC) (Jaramillo-Yáñez et al., 2020).

Técnicas de *machine learning*

Con las características extraídas, se procede a aplicar las técnicas de *machine learning*. La clasificación en *machine learning* es un método de aprendizaje supervisado que asigna etiquetas a los datos, basándose en patrones aprendidos de ejemplos anteriores. Este proceso incluye varias etapas, como elegir el modelo adecuado, entrenar con datos que ya tienen etiquetas, validar los hiperparámetros y evaluar el rendimiento usando métricas como la exactitud, la precisión y el *F1-score*.

Existen varios algoritmos de clasificación bastante populares, como los árboles de decisión, las máquinas de soporte vectorial (SVM), k vecinos más cercanos (KNN), Random Forest y XGBoost. Cada uno tiene sus propias ventajas y desventajas, dependiendo del tipo de problema y la calidad de los datos que se tienen (Wu et al., 2020).

Para mejorar la precisión de los modelos de clasificación, es crucial aplicar técnicas de preprocesamiento de datos y seleccionar características relevantes. En varios estudios se ha indicado que no eliminar características que están muy correlacionadas perjudica la precisión del modelo, por lo que hay que hacerlo para reducir el sobreajuste y mejorar la generalización en conjuntos de datos clínicos y biomédicos (Mishra y Pradhan, 2023). Además, ajustar los hiperparámetros y utilizar la validación cruzada han demostrado ser estrategias efectivas para optimizar los modelos, logrando así mejorar la clasificación en diversas tareas (Hu y Zhou, 2023). Así, implementar estrategias de optimización y usar correctamente los modelos de clasificación permite hacer predicciones más precisas y confiables en entornos de datos complejos.

Técnicas de *deep learning*

El *deep learning* ha revolucionado la clasificación de datos al permitir que los modelos aprendan automáticamente

representaciones de información a través de redes neuronales profundas. A diferencia de *machine learning*, que requiere la extracción manual de características para la clasificación, *deep learning* emplea múltiples capas de procesamiento para detectar patrones complejos en grandes volúmenes de datos no estructurados, logrando un rendimiento superior en tareas como visión por computador y procesamiento del lenguaje 10 natural (Arul, 2021). Entre los modelos más empleados en clasificación se encuentran las redes neuronales convolucionales (CNN), ampliamente aplicadas en el reconocimiento de imágenes (Li et al., 2021).

El proceso de clasificación en *deep learning* consta de varias etapas claves. En primer lugar, el modelo es entrenado con un conjunto de datos etiquetados, lo que permite que los pesos de la red neuronal se ajusten para minimizar el error en las predicciones. Posteriormente, se realiza una optimización de hiperparámetros, ajustando aspectos como la función de activación y la tasa de aprendizaje para mejorar la eficiencia del modelo (Minaee et al., 2021). Finalmente, en la fase de inferencia, el modelo clasifica nuevos datos basándose en los patrones aprendidos. Estos avances han permitido que *deep learning* supere a los enfoques tradicionales de *machine learning* en tareas de clasificación complejas, consolidándose como una herramienta clave en inteligencia artificial (Degadwala y Vyas, 2024).

Evaluación de rendimiento

Después de entrenar los modelos, se procede a evaluar su desempeño con los datos de prueba. La precisión, la exactitud, el error de clasificación y la desviación estándar son algunos de los criterios que se emplean para evaluar la eficacia del sistema HGR (Jaramillo-Yáñez et al., 2020). De acuerdo con la bibliografía existente, una buena exactitud en un modelo de ML es subjetiva, pero todo lo que supere el 70 % es un gran rendimiento del modelo. Además, una exactitud de entre el 70 % y el 90 % no solo es ideal, sino realista.

En los últimos años, la clasificación de gestos de la mano mediante señales sEMG se ha explorado ampliamente, dando lugar a propuestas que combinan distintas estrategias de adquisición, preprocesamiento, segmentación y modelos de aprendizaje automático y profundo.

A renglón seguido se presenta una comparación de estudios recientes que abordan este problema desde

Tabla 1
Comparativa de estudios recientes sobre clasificación de gestos con señales sEMG

Referencia	N.º de sujetos	N.º de canales	N.º de gestos	Ventana	Sensor	Modelos	Métricas
(Rumman et al., 2024)	19	8	12	250 ms	MFI Medical Equipment	LDA, SVM, KNN, CNN, RNN, LSTM	88,58 % (F1)
(Gehlot et al., 2024)	4	2	6	256 ms (25 % overlap)	Myoarmband	DT, RF, GB, Ada-Boost, SVM, KNN, Extra Tree, MEET	89,2 % (Acc*)
(Aarotale y Rattani, 2025)	43	8	16	600 ms (50 % overlap)	GrabMyo	ResNet50, DenseNet121, MobileNetV3, EfficientNetB0, XMANet	99,61 % (Acc)
(Miah et al., 2024)	36	8	6	3s	Myoarmband	KNN, DT, RF, SVM, Extra Trees	97,43 % (Acc)
(Challa et al., 2025)	8	4	3	250 ms	Delsys Trigno	SVM, RF, ANN, CNN	94 % (Acc)

* Acc hace referencia a la exactitud del clasificador y *F1-score*.

diversas perspectivas, considerando aspectos como el número de sujetos, canales (utiliza dos), cantidad de gestos reconocidos, duración de las ventanas de análisis, modelos empleados y métricas de desempeño alcanzadas (tabla 1).

DISCUSIÓN Y RESULTADOS

El reconocimiento automático de gestos de la mano basado en señales de sEMG se ha estudiado en los últimos años debido a su potencial para aplicaciones en interfaces hombre- máquina, prótesis activas y dispositivos de asistencia. A pesar de los avances recientes, persisten desafíos significativos que limitan la efectividad y aplicabilidad de estos sistemas. Uno de los principales problemas radica en la complejidad y variabilidad inherente de las señales sEMG, las cuales están influenciadas por factores como interferencias externas, ruido, posición de los electrodos y diferencias fisiológicas entre los usuarios (Stegeman y Hermens, 2007). En el caso del miembro superior, la masa muscular es más pequeña y delgada en comparación con el miembro inferior, lo que genera señales de menor amplitud y aumenta la dificultad para identificar patrones de intención motora consistentes (Li et al., 2021). Adicionalmente, la escasez de bases de datos etiquetadas y de alta calidad limita la capacidad de entrenar y validar modelos de aprendizaje automático de manera efectiva (Kumar y Ganesh, 2022). Esta carencia de datos diversos afecta la generalización de los modelos y su desempeño en condiciones reales.

Desafíos de generalización y validación

Metodológicamente, la exactitud del reconocimiento en tiempo real sigue siendo un reto, en especial cuando se emplean características del dominio del tiempo y ventanas deslizantes cortas (Muniandi et al., 2020). En la bibliografía existente se muestra que, si bien los enfoques basados en ML consiguen buenos resultados con características diseñadas manualmente, los modelos de DL ofrecen ventajas en la extracción automática de representaciones más robustas, aunque requieren grandes volúmenes de datos y alta capacidad computacional. No obstante, muchos sistemas que reportan resultados prometedores en entornos controlados presentan una marcada falta de robustez intersujeto; es decir, su rendimiento disminuye al aplicarse a nuevos usuarios o condiciones experimentales (Jochumsen et al., 2018). Esta limitación evidencia la necesidad de modelos más adaptativos y generalizables, que mantengan su desempeño fuera del laboratorio.

Implicaciones sociales y contexto latinoamericano

Desde una perspectiva social y tecnológica, el acceso a tecnologías de asistencia basadas en sEMG continúa siendo limitado en el ámbito global debido a los altos costos y la falta de accesibilidad (Prakash et al., 2019). Esto afecta directamente a personas con discapacidad motora en el miembro superior, quienes dependen de estas soluciones para mejorar su autonomía. En Colombia y América Latina, la disponibilidad de tecnologías

avanzadas de rehabilitación es escasa, lo que profundiza la brecha social y económica.

De acuerdo con la Federación Nacional de Asociaciones de Amputados de Colombia, la prevalencia de amputaciones en el país es de aproximadamente 3,5 personas por cada 1000 habitantes, lo que representa miles de potenciales beneficiarios de estas tecnologías (Departamento Administrativo Nacional de Estadística [DANE], 2020). Así mismo, la Encuesta Nacional de Uso del Tiempo (ENUT, 2021) reporta que el 9,6 % de las personas con discapacidad en Colombia presentan dificultades para mover o agarrar objetos con las manos, de las cuales el 71,93 % requiere ayuda externa, aunque solo el 56,47 % recibe tratamiento o terapias (DANE, 2020). Estas cifras reflejan una necesidad urgente de desarrollar soluciones accesibles y asequibles para la rehabilitación y el control de dispositivos protésicos.

En este contexto, se hace necesaria una integración interdisciplinaria entre la ingeniería biomédica, el aprendizaje automático y las ciencias de la rehabilitación, con el propósito de avanzar hacia sistemas de reconocimiento de gestos más precisos, inclusivos y socialmente relevantes, capaces de responder a los desafíos tanto técnicos como humanos del entorno real.

CONCLUSIONES

El reconocimiento automático de gestos de la mano basado en señales sEMG se consolida como una línea de investigación en crecimiento. Los estudios revisados demuestran avances en las etapas de adquisición, procesamiento y clasificación, destacándose el papel del DL como herramienta clave para automatizar la extracción de características y mejorar la precisión de los modelos en entornos controlados.

En materia de aportes, la revisión permitió identificar una tendencia hacia la optimización del preprocesamiento de señales mediante técnicas de normalización, segmentación y filtrado, así como la implementación de modelos híbridos que combinan arquitecturas convolucionales y recurrentes para captar tanto la información espacial como temporal de la señal. Además, se observa un incremento en el uso de sensores portátiles de bajo costo y la exploración de bases de datos públicas, lo que contribuye a la replicabilidad de los experimentos y a la democratización del acceso a la tecnología sEMG.

Sin embargo, persisten vacíos de investigación que limitan la transferencia de estas tecnologías al entorno clínico, entre los que se destacan la escasa disponibilidad de bases de datos etiquetadas y diversas, la variabilidad intersujeto y la falta de estandarización en los protocolos de adquisición y validación. Igualmente, la mayoría de los modelos se han probado en condiciones controladas y con sujetos sanos, por lo que su rendimiento tiende a disminuir cuando se aplican a usuarios con discapacidad o en contextos reales de rehabilitación.

En este sentido, se recomienda redoblar los esfuerzos orientados a la creación de bases de datos locales y abiertas, que incluyan sujetos con distintas características fisiológicas y condiciones clínicas. De igual manera, se propone explorar modelos híbridos que integren enfoques de ML y DL, con el fin de equilibrar rendimiento, interpretabilidad y generalización. Estas estrategias se deben acompañar de validaciones clínicas interdisciplinarias, e involucrar a expertos en ingeniería biomédica, neurorrehabilitación y aprendizaje automático, para garantizar la viabilidad técnica y funcional de los sistemas desarrollados.

Finalmente, hay que promover una colaboración continua entre academia, sector de la salud e industria tecnológica, que permita llevar los avances en sEMG desde el laboratorio hasta los entornos clínico y social. Este enfoque integral no solo fortalecerá la aplicabilidad de los modelos de reconocimiento de gestos, sino que también contribuirá al desarrollo de tecnologías de asistencia accesibles y de alto impacto social, especialmente en contextos latinoamericanos donde la rehabilitación neuromuscular y el acceso a dispositivos protésicos siguen siendo desafíos vigentes.

Autoría

El autor 1 llevó a cabo la búsqueda bibliográfica, revisó la bibliografía y redactó el manuscrito. Los autores 2 y 3 revisaron el documento, hicieron correcciones y añadieron información relevante para complementar y fortalecer el contenido final.

Conflicto de intereses: Los autores declaran que no hay conflicto de intereses.

REFERENCIAS

- Aarotale, P., y Rattani, A. (2025). Time frequency analysis of EMG signal for gesture recognition using fine-grained features. arXiv preprint. <https://doi.org/10.48550/arXiv.2504.14708>
- Arul, V. (2021). Deep learning methods for data classification. En D. Binu y B. Rajakumar (eds.), *Artificial intelligence in data mining* (pp. 87-108). Academic Press. <https://doi.org/10.1016/B978-0-12-820601-0.00001-X>
- Benalcázar, M. E., Motoche, C., Zea, J. A. et al. (2017). Real-time hand gesture recognition using the Myo armband and muscle activity detection. En *2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM)* (pp. 1-6). IEEE. <https://doi.org/10.1109/ETCM.2017.8247458>
- Burden, A. (2010). How should we normalize electromyograms obtained from healthy participants? What we have learned from over 25 years of research. *Journal of Electromyography and Kinesiology*, 20(6), 1023-1035. <https://doi.org/10.1016/j.jelekin.2010.07.004>
- Carver, J., Ganus, A., Ivey, J., Plummer, T., y Eubank, A. (2015). The impact of mobility assistive technology devices on participation for individuals with disabilities. *Disability and Rehabilitation: Assistive Technology*, 11(2). <https://doi.org/10.3109/17483107.2015.1027295>
- Challa, K., AlHmoud, I. W., Jaiswal, C., Turlapaty, A. C., y Gokaraju, B. (2025). EMG features dataset for arm activity recognition. *Data in Brief*, 60, 111519. <https://doi.org/10.1016/j.dib.2025.111519>
- Chen, X., Li, Y., Hu, R., Zhang, X., y Chen, X. (2021). Hand gesture recognition based on surface electromyography using convolutional neural network with transfer learning method. *IEEE Journal of Biomedical and Health Informatics*, 25(4), 1292-1304. <https://doi.org/10.1109/JBHI.2020.3009383>
- Chowdhury, R. H., Reaz, M. B. I., Ali, M. A. B. M., Bakar, A. A. A., Chellappan, K., y Chang, T. G. (2013). Surface electromyography signal processing and classification techniques. *Sensors*, 13(9), 12431-12466. <https://doi.org/10.3390/s130912431>
- Departamento Administrativo Nacional de Estadística (2020, noviembre). *Panorama general de la discapacidad en Colombia*. <https://www.dane.gov.co/files/investigaciones/discapacidad/Panorama-general-de-la-discapacidad-en-Colombia.pdf>
- Degadwala, S., y Vyas, D. (2024). Systematic analysis of deep learning models vs. machine learning. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, 10(4), 60-70. <https://doi.org/10.32628/CSEIT24104108>
- Gehlot, N., Jena, A., Kumar, R., y Bukya, M. (2024). MEET: Mixture of experts extra tree-based sEMG hand gesture identification. arXiv preprint. <https://doi.org/10.48550/arXiv.2405.09562>
- Gómez-Correa, M., Ballesteros, M., Salgado, I., y Cruz-Ortiz, D. (2023, mayo). Forearm sEMG data from young healthy humans during the execution of hand movements. *Scientific Data*, 10. <https://doi.org/10.1038/s41597-023-02223-x>
- Guo, L., Lu, Z., y Yao, L. (2021). Human-machine interaction sensing technology based on hand gesture recognition: a review. *IEEE Transactions on Human-Machine Systems*, 51(4), 300-309. <https://doi.org/10.1109/THMS.2021.3086003>
- Hu, H., y Zhou, Z. (2023). Evaluation and comparison of ten machine learning classification models based on the mobile users experience. En *2023 3rd International Conference on Electronic Information Engineering and Computer Science (EIECS)* (pp. 767-771). IEEE. <https://doi.org/10.1109/EIECS59936.2023.10435603>
- Hu, Y., Wong, Y., Wei, W., Du, Y., Kankanhalli, M., y Geng, W. (2018). A novel attention-based hybrid CNN-RNN architecture for sEMG-based gesture recognition. *PLOS ONE*, 13(10), e0206049. <https://doi.org/10.1371/journal.pone.0206049>
- Jaramillo-Yáñez, A., Benalcázar, M. E., y Mena-Maldonado, E. (2020). Real-time hand gesture recognition using surface electromyography and machine learning: a systematic literature review. *Sensors*, 20(9). <https://doi.org/10.3390/s20092467>
- Jiang, S., Kang, P., Song, X., Lo, B. P., y Shull, P. B. (2022). Emerging wearable interfaces and algorithms for hand gesture recognition: a survey. *IEEE Reviews in Biomedical Engineering*, 15, 85-102. <https://doi.org/10.1109/RBME.2021.3078190>
- Jochumsen, M., Waris, A., y Kamavuako, E. N. (2018). The effect of arm position on classification of hand gestures with intramuscular EMG. *Biomedical Signal Processing and Control*, 43, 1-8. <https://doi.org/10.1016/j.bspc.2018.02.013>
- Khushaba, R. (2020). A framework of temporal-spatial descriptors-based feature extraction for improved myoelectric pattern recognition. *Journal of Neural Engineering*, 17(4), 046023. <https://doi.org/10.1088/1741-2552/ab9f1b>
- Köpüklü, O., Gunduz, A., Köse, N., y Rigoll, G. (2019, febrero). Real-time hand gesture detection and classification using convolutional neural networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. <https://doi.org/10.1109/CVPRW.2019.00015>
- Kumar, D., y Ganesh, A. (2022, agosto). A critical review on hand gesture recognition using sEMG: challenges, application, process and techniques. *Journal of Physics: Conference Series*, 2327, 012075. <https://doi.org/10.1088/1742-6596/2327/1/012075>
- Kuo, Y., y Zhang, Z. (2019, mayo). Real-time pattern recognition for hand gesture based on ANN and surface EMG. En *2019 IEEE 11th International Conference on Information Technology and Artificial Intelligence Conference (ITAIC)* (pp. 799-802). IEEE. <https://doi.org/10.1109/ITAIC.2019.8785894>
- Lee, K. H., Min, J. Y., y Byun, S. (2022). Electromyogram-based classification of hand and finger gestures using artificial neural networks. *Sensors*, 22(1). <https://doi.org/10.3390/s22010225>
- Li, J., Nanchang, C., y Song, K. (2021). Research on image classification based on deep learning. En *2021 IEEE/ACIS 19th International Conference on Computer and Information Science (ICIS)* (pp. 132-136). IEEE. <https://doi.org/10.1109/ICIS51600.2021.9516872>
- Li, W., Shi, P., y Yu, H. (2021). Gesture recognition using surface electromyography and deep learning for prostheses hand: state-of-the-art, challenges, and future. *Frontiers in Neuroscience*, 15. <https://doi.org/10.3389/fnins.2021.646671>
- Ma, Y., Chen, B., Ren, P., Zheng, N., Indiveri, G., y Donati, E. (2020). EMG-based gestures classification using a mixed-signal neuromorphic processing system. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, 10(4), 578-587. <https://doi.org/10.1109/JETCAS.2020.3037951>
- Miah, A. S. M., Hassan, N., Maniruzzaman, M., Asai, N., y Shin, J. (2024). EMG-based hand gesture recognition through diverse domain feature enhancement and machine learning-based approach. arXiv preprint. <https://doi.org/10.48550/arXiv.2408.13723>

- Minaee, S., Kalchbrenner, N., Cambria, E., Nikzad, N., Chenaghlu, M., y Gao, J. (2021). Deep learning-based text classification: a comprehensive review. *ACM Computing Surveys*, 54(3). <https://doi.org/10.1145/3439726>
- Mishra, S., y Pradhan, R. K. (2023). Analyzing the impact of feature correlation on classification accuracy of machine learning model. En *2023 International Conference on Artificial Intelligence and Smart Communication (AISC)* (pp. 949-953). IEEE. <https://doi.org/10.1109/AISC56616.2023.10085293>
- Mohamed, N., Mustafa, M. B., y Jomhari, N. (2021). A review of the hand gesture recognition system: current progress and future directions. *IEEE Access*, 9, 157422-157436. <https://doi.org/10.1109/ACCESS.2021.3129650>
- Muniandi, A., Srinivasan, A., y Arjunan, S. (2020, agosto). A real-time capable linear time classifier scheme for anticipated hand movements recognition from amputee subjects using surface EMG signals. *IRBM*, 42. <https://doi.org/10.1016/j.irbm.2020.08.003>
- Ni, S., Al-Qaness, M. A., Hawbani, A., Al-Alimi, D., Abd Elaziz, M., y Ewees, A. A. (2024). A survey on hand gesture recognition based on surface electromyography: fundamentals, methods, applications, challenges and future trends. *Applied Soft Computing*, 166, 112235. <https://doi.org/10.1016/j.asoc.2024.112235>
- Nielsen, J. L., Holmgaard, S., Jiang, N., Englehart, K. B., Farina, D., y Parker, P. A. (2011). Simultaneous and proportional force estimation for multifunction myoelectric prostheses using mirrored bilateral training. *IEEE Transactions on Biomedical Engineering*, 58(3), 681-688. <https://doi.org/10.1109/TBME.2010.2068298>
- Pizzolato, S., Tagliapietra, L., Cognolato, M., Reggiani, M., Müller, H., y Atzori, M. (2017). Comparison of six electromyography acquisition setups on hand movement classification tasks. *PLOS ONE*, 12(10), e0186132. <https://doi.org/10.1371/journal.pone.0186132>
- Prakash, A., Kumari, B., y Sharma, S. (2019, agosto). A low-cost, wearable sEMG sensor for upper limb prosthetic application. *Journal of Medical Engineering & Technology*, 43, 1-13. <https://doi.org/10.1080/03091902.2019.1653391>
- Rani, G. J., Hashmi, M. F., y Gupta, A. (2023). Surface electromyography and artificial intelligence for human activity recognition: a systematic review on methods, emerging trends, applications, challenges, and future implementation. *IEEE Access*, 11, 105140-105169. <https://doi.org/10.1109/ACCESS.2023.3316509>
- Rumman, U., Ferdousi, A., Hossain, M. et al. (2024). FORS-EMG: a novel sEMG dataset for hand gesture recognition across multiple forearm orientations. arXiv preprint. <https://doi.org/10.48550/arXiv.2409.07484>
- Samadani, A.-A., y Kulic, D. (2014). Hand gesture recognition based on surface electromyography. En *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 4196-4199). IEEE. <https://doi.org/10.1109/EMBC.2014.6944549>
- Sinderby, C., Lindström, L., y Grassino, A. E. (1995). Automatic assessment of electromyogram quality. *Journal of Applied Physiology*, 79(5), 1803-1815. <https://doi.org/10.1152/jappl.1995.79.5.1803>
- Stegeman, D., y Hermens, H. (2007, enero). *Standards for surface electromyography: the European Project Surface EMG for Non-Invasive Assessment of Muscles (Seniam)* (vol. 1).
- Sultana, A., Ahmed, F., y Alam, M. S. (2023). A systematic review on surface electromyography-based classification system for identifying hand and finger movements. *Healthcare Analytics*, 3, 100126. <https://doi.org/10.1016/j.health.2022.100126>
- Weiss, L. D., Weiss, J. M., y Silver, J. K. (2015). *Easy EMG: a guide to performing nerve conduction studies and electromyography*. Elsevier Health Sciences.
- Wu, Z., Zhang, J., y Hu, S. (2020). Review on classification algorithm and evaluation system of machine learning. En *2020 13th International Conference on Intelligent Computation Technology and Automation (ICICTA)* (pp. 214-218). IEEE. <https://doi.org/10.1109/ICICTA51737.2020.00052>
- Zaheer, F., Roy, S., y De Luca, C. (2012). Preferred sensor sites for surface EMG signal decomposition. *Physiological Measurement*, 33(2), 195-206. <https://doi.org/10.1088/0967-3334/33/2/195>
- Zhang, Y., Yang, F., Fan, Q., Yang, A., y Li, X. (2022). Research on sEMG-based gesture recognition by dual-view deep learning. *IEEE Access*, 10, 32928-32937. <https://doi.org/10.1109/ACCESS.2022.3158667>
- Zheng, Z., Wu, Z., Zhao, R., Ni, Y., Jing, X., y Gao, S. (2022). A review of EMG-, FMG-, and EIT-based biosensors and relevant human-machine interactivities and biomedical applications. *Biosensors*, 12(7). <https://doi.org/10.3390/bios12070516>