

Estudio comparativo de métodos basados en reconocimiento de patrones para identificar movimientos de mano y muñeca por medio de señales SEMG

Cristian David Guerrero Méndez¹
Universidad Antonio Nariño
crguerrero69@uan.edu.co

Brayan Sneider Moreno Arévalo²
Universidad Antonio Nariño
bmoreno88@uan.edu.co

Andrés Felipe Ruiz Olaya³
Universidad Antonio Nariño
andresru@uan.edu.co

DOI:

Fecha de recepción: 05 de febrero de 2021
Fecha de aprobación: 29 de agosto de 2022

Cómo citar este artículo: Guerrero Mendez, C. D.; Moreno Arévalo, B. S.; Ruiz Olaya, A. F. (2022). Estudio comparativo de métodos basados en reconocimiento de patrones para identificar movimientos de mano y muñeca por medio de señales SEMG. *Revista Ontare*, 10, (páginas). DOI:

Resumen

Uno de los canales en la interacción *hombre-máquina* es el uso de señales de electromiografía de superficie (SEMG), las cuales, a través de técnicas de procesamiento y clasificación de características pueden proporcionar comandos para controlar dispositivos de asistencia, proporcionar accesibilidad y rehabilitación en personas en situación de discapacidad. Por ello, las metodologías de procesamiento de las señales deben enfocarse en el uso de métodos avanzados que permitan una adecuada identificación de la intención de movimiento de los usuarios. En el presente artículo, se realiza un estudio comparativo de algoritmos de reconocimiento de patrones desarrollados en Matlab para movimientos de miembro superior, relacionados con movimientos de mano y muñeca en personas diestras. Para esto, se utilizó la base de datos pública NinaPro, que proporciona registros

¹ Estudiante del programa de Ingeniería Biomédica en la Universidad Antonio Nariño. Integrante del grupo de investigación de Bioingeniería. ORCID: <https://orcid.org/0000-0003-1019-9423>

² Estudiante del programa de Ingeniería Biomédica en la Universidad Antonio Nariño. Integrante del grupo de investigación de Bioingeniería. ORCID: <https://orcid.org/0000-0001-8346-0464>

³ Ingeniero Electrónico de la Universidad del Valle (Colombia) con Especialización en Robótica de la Universidad Politécnica de Madrid (España), y Doctorado en Ingeniería Eléctrica, Electrónica y Automática de la Universidad Carlos III de Madrid (España). ORCID: <https://orcid.org/0000-0002-5883-5786>

de SEMG, mientras un usuario ejecuta diversos movimientos. En total se evaluaron 10 sujetos, 5 hombres y 5 mujeres. El algoritmo desarrollado incluye etapas de preprocesamiento, extracción de características y clasificación de patrones. La etapa de extracción de características incluyó el cálculo de raíz media cuadrática (RMS) de la señal. Se implementaron cuatro métodos de clasificación (KNN, NB, LDA y SVM), los cuales realizan una identificación de ocho movimientos isométricos e isotónicos de mano y muñeca. Como métrica de evaluación se utilizó el porcentaje de clasificación. Además, se realiza un análisis de significancia estadística para determinar diferencias entre clasificadores y grupos poblacionales. Como resultados, se determina que el mejor clasificador implementado es el SVM con un porcentaje de clasificación superior al 90 %, encontrando diferencias significativas entre los resultados de los métodos. No obstante, se observa que los hombres presentan mejores resultados que las mujeres, de acuerdo con la métrica de evaluación.

Palabras clave: *Machine learning* (ml); electromiografía de superficie (SEMG); control mioeléctrico; reconocimiento de patrones; movimientos de mano y muñeca; comparación de métodos.

Comparative Study of Methods Based on Pattern Recognition to Identify Hand and Wrist Movements through SEMG Signals

Abstract

One of the channels in human-machine interaction is the use of surface electromyography (SEMG) signals, which, through feature processing and classification techniques, can provide commands to control assistive devices, accessibility, and rehabilitation for people with disabilities. The NinaPro public database was used, which provides SEMG records while a user executes various movements. In total, 10 subjects were evaluated: 5 men and 5 women. The developed algorithm includes preprocessing, feature extraction, and pattern classification stages. The feature extraction stage included the signal's root-mean-square (RMS) calculation. Four classification methods (KNN, NB, LDA, and SVM) were implemented, identifying eight isometric and isotonic hand and wrist movements. The classification percentage was used as an evaluation metric. In addition, a statistical significance analysis is performed to determine differences between classifiers and population groups. The results determined that the best classifier implemented is the SVM, with a classification percentage higher than 90%, finding significant differences between the results of other methods. However, it is observed that men present better results than women, according to the evaluation metric.

Keywords: Machine learning (ml); surface electromyography (SEMG); myoelectric control; pattern recognition; hand and wrist movements; method comparison

Estudo comparativo de métodos baseados em reconhecimento de padrões para identificar movimentos de mão e punho por meio de sinais SEMG

Resumo

Um dos canais na interação homem-máquina é o uso de sinais de eletromiografia de superfície (SEMG), que, por meio de técnicas de processamento e classificação de características, podem fornecer comandos para controlar dispositivos de assistência, fornecer acessibilidade e reabilitação em pessoas com deficiência. Portanto, as metodologias de processamento de sinais devem focar no uso de métodos avançados que permitam a identificação adequada da intenção de movimento dos usuários. Neste artigo é realizado um estudo comparativo de algoritmos de reconhecimento de padrões desenvolvidos em Matlab para movimentos de membros superiores, relacionados a movimentos de mão e punho em pessoas destras. Para isso, foi utilizado o banco de dados público NinaPro, que fornece registros SEMG, enquanto um usuário executa diversos movimentos. No total, foram avaliados 10 sujeitos, sendo 5 homens e 5 mulheres. O algoritmo desenvolvido inclui etapas de pré-processamento, extração de características e classificação de padrões. A etapa de extração de características incluiu o cálculo da raiz quadrada média (RMS) do sinal. Foram implementados quatro métodos de classificação (KNN, NB, LDA e SVM), que identificam oito movimentos isométricos e isotônicos da mão e do punho. A porcentagem de classificação foi utilizada como métrica de avaliação. Além disso, uma análise de significância estatística é realizada para determinar diferenças entre classificadores e grupos populacionais. Como resultados, determina-se que o melhor classificador implementado é o SVM com uma porcentagem de classificação superior a 90%, encontrando diferenças significativas entre os resultados dos métodos. No entanto, observa-se que os homens apresentam melhores resultados que as mulheres, segundo a métrica de avaliação.

Palavras-chave: *Machine learning* (ml), eletromiografia de superfície (SEMG), controle mioelétrico, reconhecimento de padrões, movimentos da mão e do punho, comparação de métodos.

Etude comparative de méthodes basées sur la reconnaissance de formes pour identifier les mouvements de la main et du poignet au moyen de signaux SEMG

L'un des canaux de l'interaction homme-machine est l'utilisation de signaux d'électromyographie de surface (SEMG), qui, grâce à des techniques de traitement et de classification des caractéristiques, peuvent fournir des commandes pour contrôler les appareils d'assistance, assurer l'accessibilité et la réadaptation des personnes handicapées. Par conséquent, les méthodologies de traitement du signal doivent se concentrer sur l'utilisation de méthodes avancées permettant une identification adéquate de l'intention de mouvement des utilisateurs. Dans cet article, une étude comparative des algorithmes de reconnaissance de formes développés dans Matlab pour les mouvements des membres supérieurs, liés aux mouvements de la main et du poignet chez les droitiers, est réalisée. Pour cela, la base de données publique NinaPro a été utilisée, qui fournit des enregistrements SEMG, tandis qu'un utilisateur exécute divers mouvements. Au total, 10 sujets ont été évalués, 5 hommes et 5 femmes. L'algorithme développé comprend des étapes de prétraitement, d'extraction de caractéristiques et de classification de modèles. L'étape d'extraction des caractéristiques comprenait le calcul de la moyenne quadratique (RMS) du signal. Quatre méthodes de classification (KNN, NB, LDA et SVM) ont été mises en œuvre, qui identifient huit mouvements isométriques et isotoniques de la main et du poignet. Le pourcentage de classification a été utilisé comme mesure d'évaluation. De plus, une analyse de signification statistique est effectuée pour déterminer les différences entre les classificateurs et les groupes de population. Comme résultats, il est déterminé que le meilleur classificateur mis en œuvre est le SVM avec un pourcentage de classification supérieur à 90%, trouvant des différences significatives entre les résultats des méthodes. Cependant, on observe que les hommes présentent de meilleurs résultats que les femmes, selon la métrique d'évaluation.

Mots-clés: Apprentissage automatique; électromyographie de surface; contrôle myoélectrique; reconnaissance de formes; mouvements des mains et des poignets; comparaison de méthode

1. Introducción

De acuerdo con el último reporte de la Organización Mundial de la Salud (OMS), aproximadamente el 15,6 % de la población mundial sufre alguna discapacidad, del cual el 2,2 % tienen dificultades en el funcionamiento neuromotor (OMS, 2011). Para la población colombiana, según el DANE esta cifra se encuentra alrededor del 6,3 % (DANE, 2019). Principalmente, las dificultades neuromotoras son provocadas por accidentes cerebrovasculares (ACV, por sus siglas en inglés), lesiones en la médula espinal, parálisis cerebral, enfermedad de Parkinson, esclerosis múltiple, entre otras (Kandel, Schwartz, Jessell, Siegelbaum, Hudspeth y Mack, 2000). Por tal motivo, durante los últimos años, en la ingeniería de rehabilitación se han propuesto diferentes estrategias metodológicas que aumentan el rendimiento de los sistemas de rehabilitación para que personas en condición de discapacidad tengan una mayor facilidad y aceptación en el uso de estos sistemas (De Vries, Van Ommeren, Prange-Lasonder, Rietman y Veltink, 2018; Leone, Gentile, Cordella, Gruppioni, Guglielmelli y Zollo, 2022; Yang, Jiang, Sun, Tao, Tong, Jiang, Xu, Yun, Liu, Chen y Kong, 2021). Dentro de estos sistemas se destacan las interfaces cerebro-computador (BCI, por sus siglas en inglés), interfaces hombre-máquina (HMI, por sus siglas en inglés) y prótesis mioeléctricas (Chaudhary, Birbaumer y Ramos-Murguialday, 2016; Geethanjali, 2016; Ruiz-Olaya, Quinayas Burgos y Londono, 2019), que son controladas principalmente por la detección de la intención de movimiento de los usuarios.

La restauración de la actividad motora en movimientos de miembros superiores es de gran importancia para personas con amputación o discapacidad motora, considerando que el desarrollo de actividades de la vida diaria (ADLs) son ejecutadas principalmente por los miembros superiores (Guerrero-Méndez & Ruiz-Olaya, 2022; Rand, 2018). Los movimientos

de la mano y muñeca se encuentran en el agarre, sostenimiento y levantamiento de objetos, además de estar involucrados en actividades vitales como el consumo de alimentos (Guerrero-Méndez & Ruiz-Olaya, 2022; Rand, 2018). Por tal motivo, identificar las tareas motoras relacionadas con los diferentes tipos de movimientos que se pueden realizar con la mano y muñeca, es esencial para el control adecuado de una prótesis de miembro superior, que podría aumentar la usabilidad de dispositivos basados en control mioeléctrico (Kim, Park, Lim y Lee, 2021).

La electromiografía de superficie (SEMG) registra la actividad eléctrica muscular generada por una contracción voluntaria cuando una persona tiene la intención de realizar un movimiento (Vigotsky, Halperin, Lehman, Trajano y Vieira, 2018). Esto se realiza ubicando los electrodos sobre la superficie de los músculos activos. El registro de estas señales depende de factores externos como la intensidad e intención de contracción, las propiedades de los electrodos y de la piel del sujeto, la distancia entre los electrodos, la posición del miembro, el tiempo y la calidad del contacto (Bi, Feleke y Guan, 2019). Estos factores, relacionados con condiciones ambientales no ideales, tienden a afectar el porcentaje de exactitud en el reconcomiendo de patrones asociados a un movimiento. Por tal motivo, la evaluación e implementación de diferentes estrategias metodológicas aún se encuentra bajo estudio.

El control mioeléctrico basado en el reconocimiento de patrones se implementa mediante dos fases principales: la primera corresponde a la extracción de características donde los métodos más usados son el valor medio absoluto (VAM), integral de valor absoluto (AVI), raíz cuadrática media (RMS), amplitud de Willison, y modelos autorregresivos (AR), mientras que la fase de clasificación o identificación de los movimientos corresponde a la segunda, en la cual se han implementado métodos de *machine learning* (ML) para identificar los patrones relacionados con la intención de movimiento. Entre los métodos se encuentra el K-vecinos cercanos (KNN), análisis discriminante lineal (LDA), máquina de soportes vectoriales (SVM) y redes neuronales (NN) (Amanpreet, 2019; Atzori, Gijsberts, Castellini, Caputo, Hager, Elsig,

Giatsidis, Bassetto y Müller, 2014; López Delis & Ruiz Olaya, 2012; Rajapriya, Rajeswari y Thiruvengadamet, 2021). A través de diferentes arquitecturas metodológicas, las señales de SEMG han sido usadas en aplicaciones de asistencia y rehabilitación robótica, diagnóstico y aplicaciones clínicas, telerobots, reconocimiento de patrones, entre otras (Bi *et al.*, 2019). Adicionalmente, el reconocimiento de patrones ha sido implementado en la identificación de imágenes, datos médicos, campos biomédicos y biológicos, entre otros (Paolanti y Frontoni, 2020). Así como también se han reportado aplicaciones relacionadas con el desarrollo de métodos novedosos para la implementación en sistemas de rehabilitación motora, usando otro tipo de señales como electroencefalografía (EEG) en el registro de la actividad cerebral (Guerrero-Méndez *et al.*, 2021a,b).

Por otro lado, el control mioeléctrico puede ser usado junto con sistemas de rehabilitación basados en estimulación eléctrica funcional (FES), la cual es una técnica que se fundamenta en la activación nerviosa controlada por medio de corriente eléctrica para producir una respuesta en los músculos o nervios (Doucet, Lam y Griffin, 2012). Esta técnica se ha implementado para el control artificial de los músculos en respuesta a la intencionalidad del paciente, convirtiéndose en una alternativa en el campo de la ingeniería de rehabilitación para restaurar la funcionalidad motora (Doucet *et al.*, 2012).

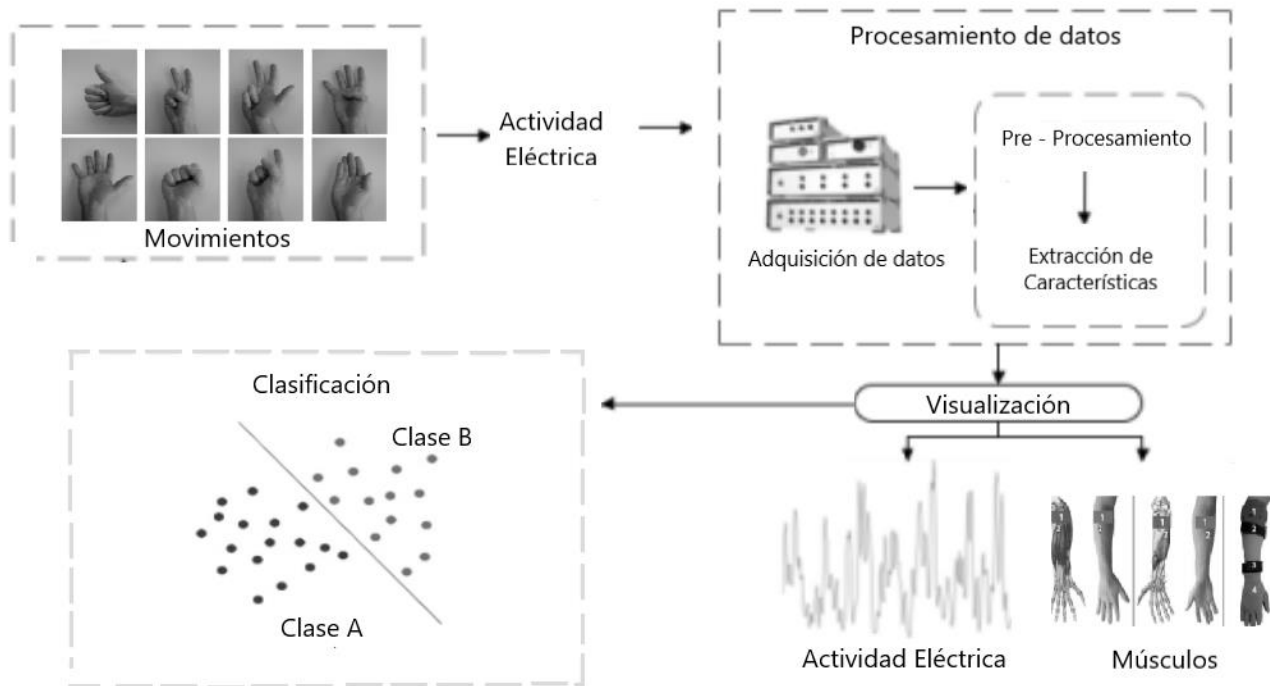
En la actualidad, uno de los retos del control mioeléctrico es identificar estrategias metodológicas adecuadas para aumentar el rendimiento de los métodos en la identificación de la intencionalidad de movimiento en personas en condición de discapacidad. Por lo tanto, en este trabajo se realiza un estudio comparativo de métodos basados en ML para la identificación de características de señales de SEMG, en el reconocimiento de ocho movimientos de mano y muñeca. Para esto se utilizó un conjunto de datos públicos NinaPro, que registra 40 sujetos sanos, se utilizó el método de extracción de características RMS y cuatro métodos de ML para la identificación de movimientos. Adicionalmente, se realizaron estudios estadísticos entre métodos y grupos poblacionales.

El artículo está organizado de la siguiente manera: la segunda sección describe la metodología experimental utilizada en la investigación, que incluye el protocolo, procesamiento de las señales e implementación de los algoritmos. La tercera sección describe los resultados obtenidos. La cuarta presenta la discusión de los resultados, y finalmente, las conclusiones se abordan en la quinta sección.

2. Metodología

La figura 1 presenta la metodología implementada para el procesamiento de las señales de SEMG. Inicialmente, se muestran los movimientos que serán ejecutados, posteriormente se realiza la adquisición de los datos, luego el procesamiento y extracción de las características. Por último, se visualizan las señales y las características para posteriormente clasificar los patrones asociados a cada movimiento realizado.

Figura 1. Diagrama de bloques de la fase de procesamiento, visualización e identificación de los ocho movimientos analizados



Fuente. Elaboración propia.

2.1 Descripción base de datos

Para este trabajo se utilizó un conjunto de datos públicos de la base NinaPro BD2 (Atzori *et al.*, 2014), la cual registra movimientos de miembro superior, específicamente movimientos de mano y muñeca en 40 sujetos sanos, tanto en hombres como en mujeres, que realizan un total de 50 movimientos divididos en cuatro fases: movimientos de los dedos con configuraciones isométricas e isotónicas, movimientos de muñeca, movimientos de agarre y patrones de fuerza. La base de datos cuenta con información cinemática de la posición de la mano, y datos eléctricos relacionados con las activaciones musculares registradas por SEMG.

Las señales de SEMG se registran mediante 12 electrodos de doble diferencial, a través de un sistema inalámbrico *Delsys Trigno*, los cuales están ubicados de la siguiente forma:

- Ocho electrodos están distribuidos alrededor del antebrazo con un espaciado uniforme, los cuales adquieren la activación muscular cercana a la articulación del radio humeral.
- Dos electrodos están distribuidos en puntos de mayor nivel de activación muscular del flexor y extensor de los dedos.
- Dos electrodos están distribuidos en puntos estratégicos del bíceps y el tríceps.

La ubicación de cada electrodo fue seleccionada mediante la estrategia de posicionamiento anatómico preciso, con el fin de obtener un muestreo denso, con las mejores características de las señales fisiológicas. La frecuencia de muestreo de las señales de SEMG es de 2 KHz.

En el protocolo experimental, a los sujetos se les proporcionó una indicación visual por medio de una imagen utilizando la pantalla del computador; esta imagen mostraba el movimiento que se debía ejecutar. Se le pidió a cada sujeto repetir el movimiento teniendo en cuenta la imagen presentada en la pantalla. El movimiento debía ser ejecutado en 5 segundos seguido de 3 s de descanso. Para este estudio se incluyeron 6 repeticiones por cada movimiento.

2.2 Selección de sujetos

Para este estudio, se utilizaron 10 sujetos de la base de datos, divididos en 5 hombres y 5 mujeres. Se tuvieron en cuenta los ocho primeros movimientos relacionados con movimientos isométricos e isotónicos de la mano y la muñeca (véase Figura 2), y únicamente se incluyeron en el análisis las señales de SEMG. En la selección de los sujetos, el criterio de inclusión se enfocó en la ejecución de los movimientos con la mano derecha (sujetos diestros). De acuerdo con los sujetos seleccionados, se presenta en la tabla 1 la media y desviación estándar de los datos antropométricos entre géneros. Los movimientos analizados en el estudio, se seleccionaron de acuerdo con reportes en la literatura científica

referente a la robótica en miembros superiores (Atzori *et al.*, 2014; Kim *et al.*, 2021; Rajapriya *et al.*, 2021).

Tabla 1. Valor promedio de edad, estatura y peso entre géneros

Géneros	Edad	Estatura	Peso
Hombres	35 ± 10	189 ± 7	76 ± 3
Mujeres	31 ± 4	162 ± 8	57 ± 5

Fuente. Elaboración propia.

Figura 2. Movimientos de mano y muñeca analizados en el estudio



Fuente. Atzori *et al.*, 2014.

2.3 Preprocesamiento

Los datos registrados de SEMG fueron procesados mediante un filtro pasa banda para remover artefactos que pudieran generar distorsión y afectación en la señal de SEMG. Para esto, un filtro Butterworth de octavo orden fue utilizado en la banda de paso (20 Hz - 500 Hz). En esta banda de frecuencia se presenta la mayor energía y potencia de la señal de SEMG (Merletti, Botter, Troiano, Merlo y Minetto, 2009). Adicionalmente, se realizó una segmentación de los datos con respecto a la cantidad de ensayos y movimientos analizados por cada sujeto.

2.4 Extracción de características

En el procesamiento de las señales, se realizó una segmentación en ventanas de tiempo de 300 ms sobrepuestas al 50 % (López Delis & Ruiz Olaya, 2012). La extracción de características se realizó en el dominio del tiempo, para esto se utilizó la raíz media cuadrática (RMS), que extrae las características de la amplitud eléctrica de la señal, la cual es descrita en la ecuación 1. Se realizó el procesamiento para cada ventana de datos y para los 12 canales de SEMG. Finalmente, la matriz de características está dada por el número de ventanas (filas) y el número de canales (columnas).

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N |X_i|^2} \quad (1)$$

Donde N es la longitud de la ventana, y X_i es la señal de SEMG para cada muestra i .

2.5 Identificación de movimientos

Para la identificación de los movimientos se usaron los clasificadores KNN, LDA, SVM y *Naive Bayes* (NB), configurados para una clasificación multiclase de los ocho movimientos de mano y muñeca, usando el *software* Matlab (Versión R2020b, MathWorks Inc). El método KNN fue configurado con cinco vecinos cercanos usando la métrica de distancia euclidiana, el método SVM fue configurado con la función Kernel lineal y el método NB con una función Gaussiana. La evaluación de los modelos fue realizada dividiendo los datos en 50 % para entrenamiento y 50 % para prueba, evaluando los métodos en 10 grupos de validación cruzada. De acuerdo con esto, de los seis ensayos registrados por cada movimiento, se usaron tres ensayos para entrenar los modelos y los otros tres para probar. La organización de la base datos para los movimientos tanto de entreno como de evaluación fue realizada aleatoriamente.

El rendimiento de los métodos se evaluó utilizando la métrica de porcentaje de clasificación (PC) que se describe en la ecuación 2. Esta métrica se define como el porcentaje de ensayos que se clasifican correctamente, y se calcula de la siguiente manera:


$$PC = \frac{\# \text{ de aciertos en la identificación de movimientos}}{\# \text{ total de movimientos}} * 100 \quad (2)$$

2.6 Análisis estadístico

Se realizó un análisis estadístico para determinar si existen diferencias significativas en el rendimiento de cada método usado para la identificación de los movimientos. Primero se determinó el tipo de distribución y la homogeneidad de varianzas de los datos, usando la prueba de Shapiro-Wilk y Levene, respectivamente. Después de verificar que los datos presentaran una distribución normal y las varianzas homogéneas, se aplicó la prueba paramétrica; análisis de varianza ANOVA con un valor p de 0,05 y con una prueba *post-hoc* de Bonferroni para realizar comparaciones múltiples entre los clasificadores. La hipótesis alternativa se enfocó en determinar si existen diferencias significativas entre el rendimiento de los clasificadores y los grupos poblacionales de hombres y mujeres de acuerdo con los resultados de la métrica de evaluación.

3. Resultados

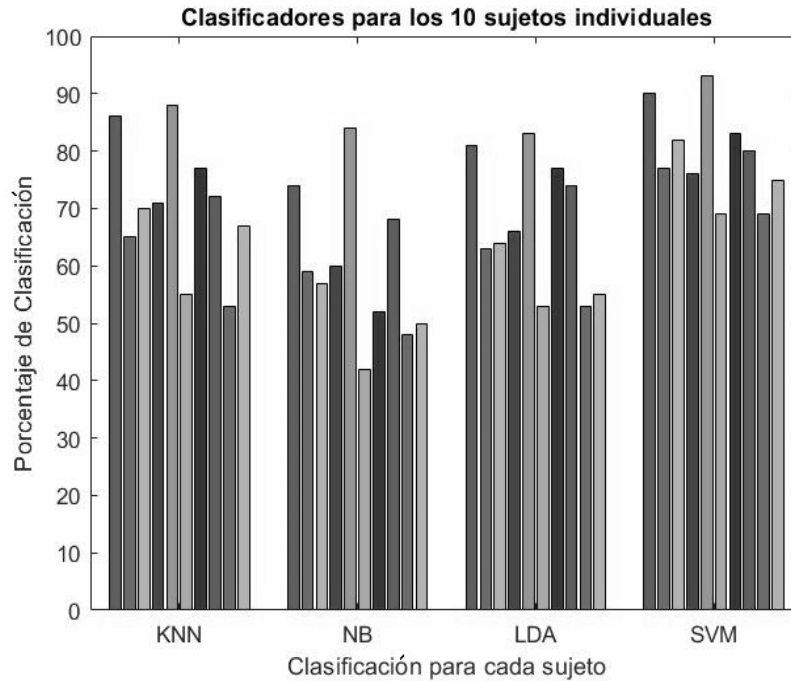
Figura 3. Características obtenidas para el conjunto de entrenamiento y prueba usando el valor RMS en el sujeto 5



Fuente. Elaboración propia.

Teniendo en cuenta el conjunto de patrones obtenidos, la figura 3 presenta las características de las señales de SEMG extraídas, usando el valor RMS en los datos de entrenamiento y evaluación. La figura presenta las características para el sujeto número 5, donde se presentan los patrones para los ocho movimientos en las tres repeticiones de entrenamiento y en las tres repeticiones de evaluación. En la figura, las tonalidades de color representan los canales de SEMG.

Figura 4. Resultados del porcentaje de clasificación de cada sujeto en cada clasificador

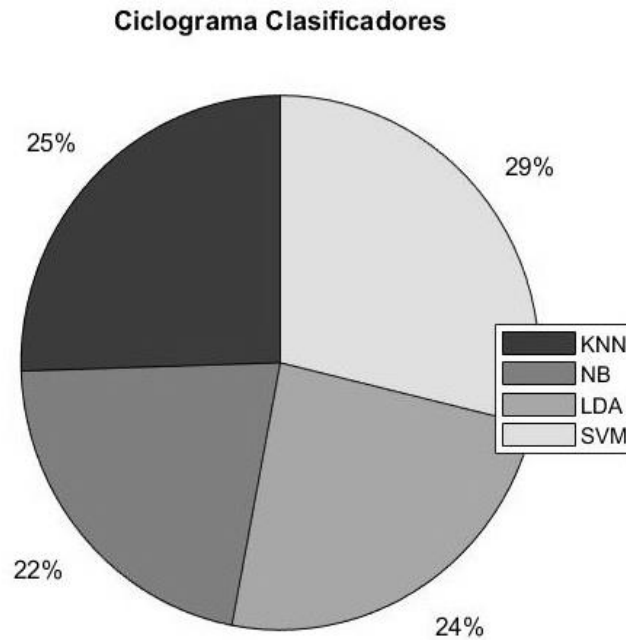


Nota. Las primeras 5 barras corresponden a los resultados de los hombres y las 5 últimas a los de las mujeres.

Fuente. Elaboración propia.

Por otro lado, la figura 4 presenta el porcentaje de clasificación de cada clasificador evaluado en los sujetos. El sujeto 1 y 5 son los que presentan el mejor porcentaje de clasificación para todos los clasificadores, con un valor aproximado para el clasificador KNN de 86 % y 88 %, para el NB de 74 % y 84 %, para LDA de 81 % y 83 %, y para el SVM de 90 % y 93 %, respectivamente. De igual forma, los sujetos que presenta el menor porcentaje de clasificación son el 6 y el 9 con un valor aproximado de KNN 55 % y 53 %, para el NB de 42 % y 48 %, para LDA de 53 % y 53 %, y para el SVM de 69 % y 69 %. Es importante resaltar que el análisis se realizó para un grupo poblacional de 5 hombres y 5 mujeres.


Figura 5. Comparación entre los resultados de los clasificadores usando todos los sujetos



Fuente. Elaboración propia.

En la figura 5 se puede evidenciar cuál clasificador presenta mejor rendimiento considerando la métrica de evaluación. Para ello, se utilizó la media del porcentaje de clasificación de cada método en todos los sujetos, se sumaron todas las medias y a través de la relación entre el rendimiento de cada método y la suma total, se cuantificaron porcentualmente las diferencias de los resultados entre los clasificadores. De acuerdo con esto, el clasificador SVM presenta mejores resultados. No obstante, se puede determinar que los resultados entre KNN y LDA son similares, y que el método NB es el que presenta un menor rendimiento.

Figura 6. Clasificación dividida por género para cada clasificador



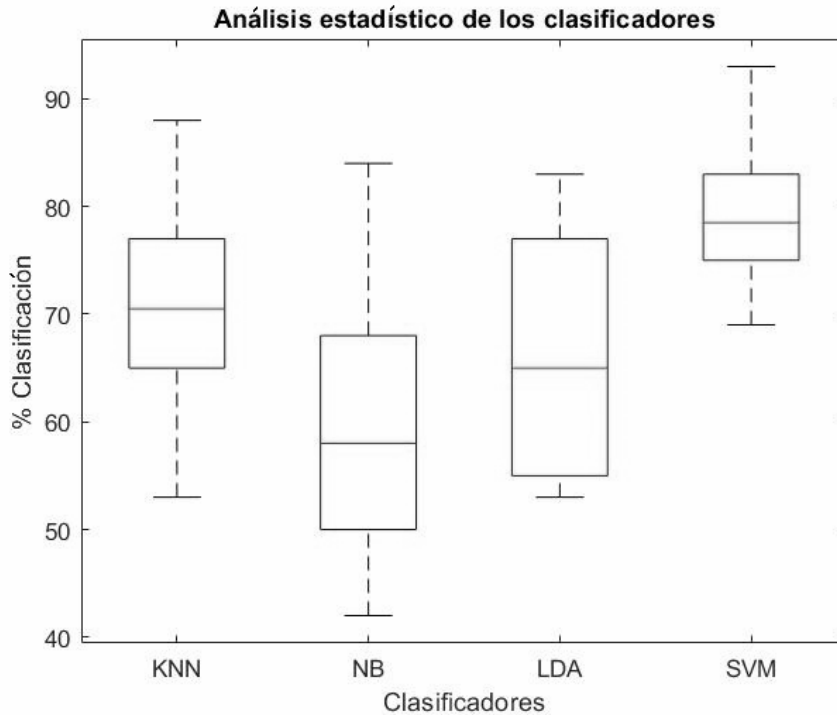
Fuente. Elaboración propia.

En la figura 6, se presentan los resultados del porcentaje de clasificación por género para cada uno de los métodos. Se puede determinar que los resultados de los cuatro clasificadores tienden a generar un mejor rendimiento cuando los movimientos son realizados por los hombres. Para el algoritmo NB, se evidencia mayor diferencia entre géneros, aproximadamente del 15 %. Así mismo, se evidencia que en la clasificación por género el SVM presenta un mejor rendimiento en comparación con los otros métodos, tanto en hombres (83,6 %) como en mujeres (75,2 %). No obstante, el clasificador con los resultados más bajos es el NB con un 66 % en hombres y 52 % en mujeres.

Por otra parte, la figura 7 presenta la distribución de resultados para cada clasificador sin tener en cuenta el género. Mediante esta gráfica es posible reconocer la media de cada clasificador, además de su valor máximo y mínimo de acuerdo con la dispersión de los datos y el rango intercuartílico. El SVM es el método con menor dispersión y diferencia

intercuartílica, que a su vez, presenta una media superior del porcentaje de clasificación en comparación con los otros métodos.

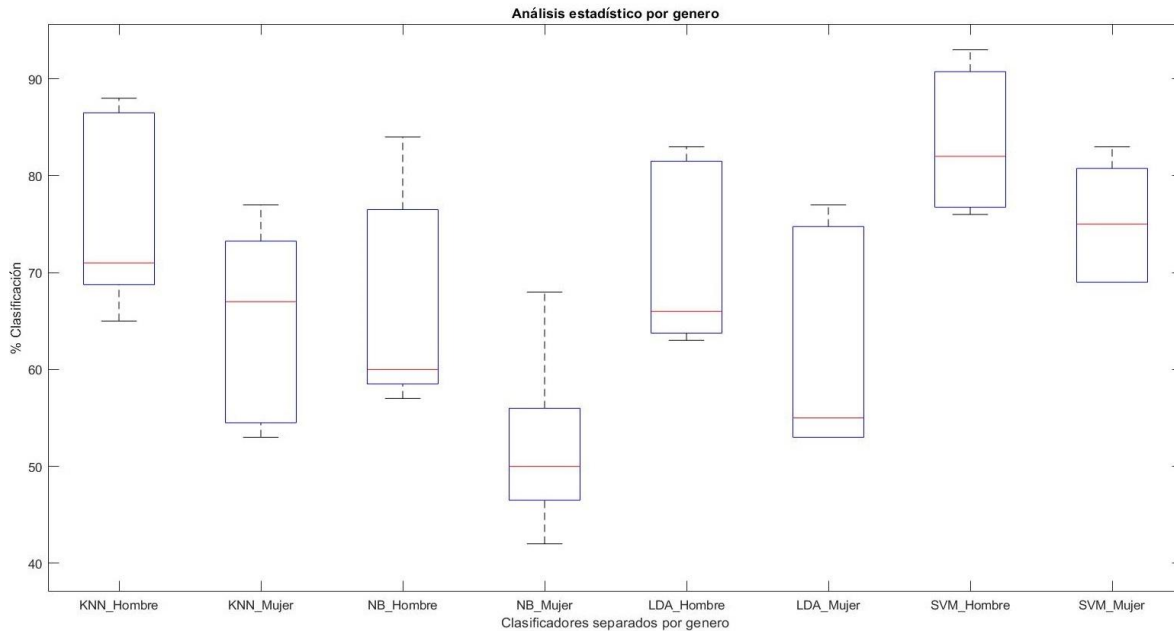
Figura 7. Diagrama de caja y bigotes para cada clasificador sin tener en cuenta el género



Fuente. Elaboración propia.

En la figura 8, se muestran los resultados por género para cada clasificador. Se evidencia que los hombres presentan una media porcentual de clasificación superior a la de las mujeres para los cuatro clasificadores. El método con mayor dispersión es el NB, de igual forma es el que presenta menor porcentaje de clasificación, tanto en hombres como en mujeres. Por el contrario, el clasificador con menor dispersión y mayor porcentaje de clasificación es el SVM, en los dos géneros.

Figura 8. Diagrama de caja y bigotes para cada clasificador teniendo en cuenta el género

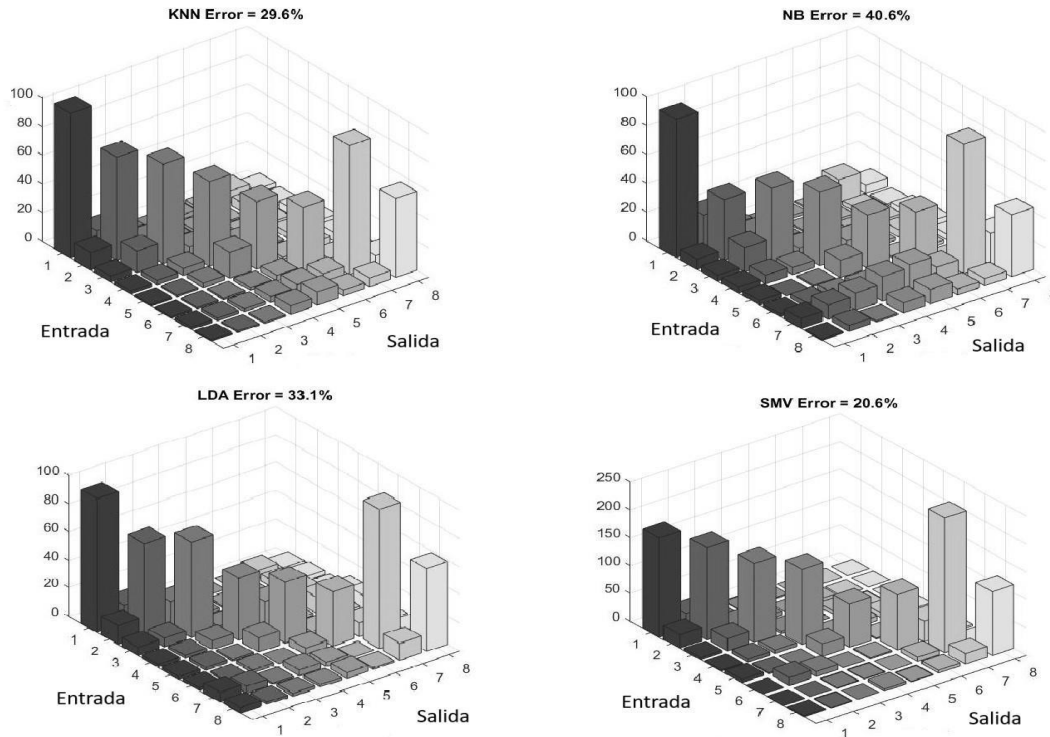


Fuente. Elaboración propia.

Por último, la figura 9 presenta los resultados obtenidos de todos los sujetos en matrices de confusión para cada uno de los clasificadores. Cada entrada y salida corresponde a cada uno de los ocho movimientos analizados, los cuales son organizados sucesivamente de acuerdo con la figura 2. Con estos resultados, se puede observar la tasa de error para cada clasificador, donde se evidencia que el clasificador con los mejores resultados para la clasificación de las ocho tareas es el SVM, con un porcentaje de error medio del 20,6 %, y se observa que el método con peores resultados es el clasificador NB, con un error medio de 40,6 %.

Adicionalmente, de acuerdo con los resultados de la figura 9, se puede determinar que el movimiento que mejor identifican los métodos es el presentado en el movimiento 7 de acuerdo con la figura 1. Por otro lado, los movimientos que más dificultades presentan para ser identificados, son el 5 y 6 respecto a la identificación con los otros movimientos (véase Figura 1).

Figura 9. Matriz de confusión para cada clasificador implementado, resaltando el error de clasificación para los ocho movimientos de mano y muñeca



Fuente. Elaboración propia.

4. Discusión

En este estudio se abordó un problema de clasificación relacionado con la identificación de ocho movimientos de miembro superior, provenientes de contracciones isométricas e isotónicas. Se realizó una comparación entre clasificadores y grupo poblacional de géneros, de acuerdo con los resultados de porcentaje de clasificación.

Uno de los retos actuales dentro de la comunidad científica relacionada con la rehabilitación de miembros superiores e inferiores, aplicando sistemas basados en prótesis mioeléctricas, recae en el desarrollo de metodologías de procesamiento que permitan mejorar la identificación de patrones asociados a la intención de movimiento a través de señales de

SEMG. Dentro de estos sistemas de rehabilitación, el rendimiento en la identificación de movimientos puede verse afectado por condiciones no ideales, relacionadas con localización de los electrodos, la piel de los sujetos, variabilidad de los sujetos, y otro tipo de condiciones ambientales. Además de factores que pueden interferir directamente en la señal de SEMG, como el ruido provocado por una fuente física o biológica.

En la literatura, se han presentado diferentes enfoques de control mioeléctrico en la aplicación de métodos computacionales para la identificación de movimientos de miembro superior. Según Amanpreet (2019) se clasifican diferentes movimientos del hombro a partir de sujetos con amputación transhumeral usando métodos de ML como SVM, KNN y LDA con resultados por encima del 90 %. Por otro lado, en Rajapriya *et al.* (2021) se presenta un enfoque de aprendizaje profundo (*Deep Learning*) y redes neuronales artificiales en la identificación de movimientos de la mano bajo variaciones dinámicas, con resultados de porcentaje de clasificación por encima del 95 %. Otros estudios han destacado el clasificador KNN en la identificación de siete movimientos de mano con un error de clasificación de aproximadamente 5,9 % usando un brazo robótico (Ruiz-Olaya *et al.*, 2019). Finalmente, estudios recientes han presentado enfoques usando ML en la identificación de la intención de movimiento en tareas de alcance para agarrar objetos, y tareas de mano y muñeca con resultados superiores al 90 % (De Vries *et al.*, 2018; Leone *et al.*, 2022). De acuerdo con esto, es posible reconocer que los estudios enfocados en SEMG aún se encuentran en estudio, debido a que los sistemas de rehabilitación basados en control mioeléctrico son de gran importancia en la recuperación de la función motora de personas en condición de discapacidad.

En este artículo, se abordaron métodos de clasificación estándar ampliamente implementados en la literatura para el reconocimiento de movimientos de miembro superior en aplicaciones de control mioeléctrico. De acuerdo con los resultados estadísticos, se puede determinar que existen diferencias significativas entre el rendimiento de los clasificadores con un valor de $p < 0,05$. Sin embargo, a través de la prueba *post-hoc* de Bonferroni se puede determinar que únicamente los resultados de los métodos de NB y SVM presentan diferencias

significativas. Adicionalmente, para la evaluación de los géneros no se encontraron diferencias significativas $p < 0,05$.

Los resultados de la investigación tienen gran importancia en la implementación de procesos de rehabilitación motora usando prótesis mioeléctricas, debido a que una adecuada identificación de los movimientos provocados por contracciones voluntarias en los movimientos de mano y muñeca, podría aumentar la eficacia de las metodologías de rehabilitación relacionadas con la facilidad de uso, controlabilidad y adaptabilidad en el uso de estos sistemas. No obstante, dentro del estudio existen limitaciones relacionadas con la muestra poblacional utilizada, comparación de los resultados implementando métodos más sofisticados como los basados en redes neuronales y aprendizaje profundo, y comparaciones entre métodos de extracción de características, basados en el dominio del tiempo y frecuencia.

5. Conclusiones

De acuerdo con los resultados del estudio, es posible concluir que el método de clasificación SVM presenta mejor rendimiento en el porcentaje de clasificación con un valor máximo de 92 %, comparado con los resultados de los métodos NB, LDA y KNN para la identificación de los ocho movimientos de mano y muñeca. De manera adicional, se concluye que, de acuerdo con la muestra poblacional seleccionada, los hombres presentan un mejor rendimiento en la clasificación por encima del 80 %.

Los estudios futuros se enfocarán en la aplicación de estos métodos, en la identificación de movimientos en tiempo real usando prótesis mioeléctricas bajo condiciones no ideales. Además, se propone el uso de métodos avanzados, basados en aprendizaje profundo, que permitan comparar, no solo el rendimiento en la clasificación, sino también el costo computacional en el uso de estos métodos. Y por último, se propone el uso de estos métodos en la validación de metodologías usando dos diferentes modalidades de adquisición de información neuronal como la basada en EEG.

Agradecimientos

Agradecemos a la Facultad de Ingeniería Mecánica, Electrónica y Biomédica, y al semillero de investigación de Bioingeniería de la Universidad Antonio Nariño por el soporte en el desarrollo del presente trabajo.

Referencias

- Amanpreet, K. (2019). Machine learning-based novel approach to classify the shoulder motion of upper limb amputees. *Biocybernetics and Biomedical Engineering*, 39(3), 857-867. DOI: <https://doi.org/10.1016/j.bbe.2019.07.007>
- Atzori, M.; Gijsberts, A.; Castellini, C.; Caputo, B.; Hager, A. G. M.; Elsig, S.; Giatsidis, G.; Bassetto, F.; Müller, H. (2014). Electromyography data for non-invasive naturally-controlled robotic hand prostheses. *Scientific Data*, 1(1), 140053. DOI: <https://doi.org/10.1038/sdata.2014.53>
- Bi, L.; Feleke, A.; Guan, C. (2019). A review on EMG-based motor intention prediction of continuous human upper limb motion for human-robot collaboration. *Biomedical Signal Processing and Control*, 51, 113-127. DOI: <https://doi.org/10.1016/j.bspc.2019.02.011>
- Chaudhary, U.; Birbaumer, N.; Ramos-Murguialday, A. (2016). Brain-computer interfaces for communication and rehabilitation. *Nature Reviews Neurology*, 12(9), 513-525. DOI: <https://doi.org/10.1038/nrneurol.2016.113>
- De Vries, J.; Van Ommeren, A.; Prange-Lasonder, G.; Rietman, J.; Veltink, P. (2018). Detection of the intention to grasp during reach movements. *Journal of Rehabilitation and Assistive Technologies Engineering*, 5. DOI: <https://doi.org/10.1177/2055668317752850>
- Departamento Administrativo Nacional de Estadística. (DANE). (2019). *Sala situacional de las Personas con Discapacidad*. Ministerio de Salud y Protección Social.
- Doucet, B. M.; Lam, A.; Griffin, L. (2012). Neuromuscular electrical stimulation for skeletal muscle function. *The Yale Journal of Biology and Medicine*, 85(2), 201-215. Recuperado de <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3375668/>
- Geethanjali, P. (2016). Myoelectric control of prosthetic hands: State-of-the-art review. *Medical Devices*, 9, 247-255. DOI: <https://doi.org/10.2147/MDER.S91102>

- Guerrero-Mendez, C. D.; Blanco-Díaz, C. F.; Ruiz-Olaya, A. F. (2021a). *How do factors of comfort, concentration, and eye fatigue affect the performance of a BCI system based on SSVEP?* Paper presented at 2021 IEEE 2nd International Congress of Biomedical Engineering and Bioengineering (CI-IB&BI). Bogotá, Colombia, 13-15 October. DOI: <https://doi.org/10.1109/CI-IBBI54220.2021.9626107>
- Guerrero-Mendez, C. D.; Blanco-Díaz, C. F.; Ruiz-Olaya, A. F. (2021b). *Identification of motor imagery tasks using power-based connectivity descriptors from EEG signals.* Paper presented at 2021 XXIII Symposium on Image, Signal Processing and Artificial Vision (STSIVA). Popayán, Colombia, 11 de noviembre. DOI: <https://doi.org/10.1109/STSIVA53688.2021.9591997>
- Guerrero-Mendez, C. D.; Ruiz-Olaya, A. F. (2022). Coherence-based connectivity analysis of EEG and EMG signals during reach-to-grasp movement involving two weights. *Brain-Computer Interfaces*, 9(3), 140-154. DOI: <https://doi.org/10.1080/2326263X.2022.2029308>
- Kandel, E. R.; Schwartz, J. H.; Jessell, T. M.; Siegelbaum, S.; Hudspeth, A. J.; Mack, S. (Eds.). (2000). *Principles of neural science* (Vol. 4, pp. 1227-1246). New York: McGraw-Hill.
- Kim, K. T.; Park, S.; Lim, T. H.; Lee, S. J. (2021). Upper-Limb electromyogram classification of reaching-to-grasping tasks based on convolutional neural networks for control of a prosthetic hand. *Frontiers in Neuroscience*, 15, 733359. DOI: <https://doi.org/10.3389/fnins.2021.733359>
- Leone, F.; Gentile, C.; Cordella, F.; Gruppioni, E.; Guglielmelli, E.; Zollo, L. (2022). A parallel classification strategy to simultaneous control elbow, wrist, and hand movements. *Journal of NeuroEngineering and Rehabilitation*, 19(1), 1-17. DOI: <https://doi.org/10.1186/s12984-022-00982-z>
- López Delis, A.; Ruiz Olaya, A. F. (2012). Métodos computacionales para el reconocimiento de patrones mioeléctricos en el control de exoesqueletos robóticos: una revisión. *Revista Nodo*, 3(5), 42-59. Recuperado de <https://revistas.uan.edu.co/index.php/nodo/article/view/350>
- Merletti, R.; Botter, A.; Troiano, A.; Merlo, E.; Minetto, M. A. (2009). Technology and instrumentation for detection and conditioning of the surface electromyographic signal: State of the art. *Clinical Biomechanics*, 24(2), 122-134. DOI: <https://doi.org/10.1016/j.clinbiomech.2008.08.006>
- Organización Mundial de la Salud. (OMS). (2011). *Informe mundial sobre la discapacidad*. Recuperado de https://www.afro.who.int/sites/default/files/2017-06/9789240688230_spa.pdf

- Paolanti, M.; Frontoni, E. (2020). Multidisciplinary pattern recognition applications: A review. *Computer Science Review*, 37, 100276. DOI: <https://doi.org/10.1016/j.cosrev.2020.100276>
- Rajapriya, R.; Rajeswari, K.; Thiruvengadam, S. J. (2021). Deep learning and machine learning techniques to improve hand movement classification in myoelectric control system. *Biocybernetics and Biomedical Engineering*, 41(2), 554-571. DOI: <https://doi.org/10.1016/j.bbe.2021.03.006>
- Rand, D. (2018). Proprioception deficits in chronic stroke—Upper extremity function and daily living. *PLoS ONE*, 13(3), e0195043. DOI: <https://doi.org/10.1371/journal.pone.0195043>
- Ruiz-Olaya, A. F.; Quinayas Burgos, C. A.; Londono, L. T. (2019). *A low-cost arm robotic platform based on myoelectric control for rehabilitation engineering*. Paper presented at 2019 IEEE 10th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON). New York, Estados Unidos, 13 de febrero. DOI: <https://doi.org/10.1109/UEMCON47517.2019.8993080>
- Vigotsky, A. D.; Halperin, I.; Lehman, G. J.; Trajano, G. S.; Vieira, T. M. (2018). Interpreting signal amplitudes in surface electromyography studies in sport and rehabilitation sciences. *Frontiers in Physiology*, 8, 985. DOI: <https://doi.org/10.3389/fphys.2017.00985>
- Yang, Z.; Jiang, D.; Sun, Y.; Tao, B.; Tong, X.; Jiang, G.; Xu, M.; Yun, J.; Liu, Y.; Chen, B.; Kong, J. (2021). Dynamic gesture recognition using surface EMG signals based on multi-stream residual network. *Frontiers in Bioengineering and Biotechnology*, 9, 779353. DOI: <https://doi.org/10.3389/fbioe.2021.779353>