



UNIVERSIDAD DEL AZUAY

FACULTAD DE CIENCIA Y TECNOLOGÍA

ESCUELA DE INGENIERÍA ELECTRÓNICA

**“Adquisición y clasificación de señales de electromiografía para la
detección del movimiento de la mano en lenguaje de señas”**

Trabajo de graduación previo a la obtención del título de:

Ingeniero Electrónico

Autores:

**Ebbie Milena Manchay Ruiz
Johe Santiago Quezada Fajardo**

Director:

Mst. Omar Alvarado Cando

**Cuenca, Ecuador
2023**

ADQUISICIÓN Y CLASIFICACIÓN DE SEÑALES DE ELECTROMIOGRAFÍA PARA LA DETECCIÓN DEL MOVIMIENTO DE LA MANO EN LENGUAJE DE SEÑAS

En el mundo existen millones de personas con discapacidad auditiva que se comunican a través del lenguaje de señas y se adaptan para comunicarse con personas que no tienen esta condición. Con el propósito de brindar un soporte al lenguaje de señas, este proyecto presenta como objetivo clasificar y reconocer las vocales del lenguaje de señas mediante el uso de electromiografía. Para la adquisición de datos se utilizaron dos sensores Myoware y un microcontrolador, recolectando la señal de los músculos “flexor profundo de los dedos” y “flexor largo del pulgar”. Luego, se realizó el procesamiento de señal en el cual los datos se normalizaron y unificaron para los algoritmos de clasificación. Se aplicaron técnicas de aprendizaje automático para los clasificadores KNN, RF, SVM, MLP. Los resultados obtenidos dieron una precisión de 0.6035 para KNN, un 0.4852 de RF, 0.3905 de SVM y un 0.3550 de MLP, demostrando que el algoritmo con la mejor tasa de reconocimiento es el algoritmo KNN.

Palabras clave: algoritmos de clasificación; aprendizaje automático; electromiografía; lenguaje de señas; reconocimiento de gestos.

Omar Alvarado Cando

Director de Tesis



DANIEL ESTEBAN
ITURRALDE PIEDRA

Daniel Esteban Iturralde Piedra

Director de Escuela

Ebbie Milena Manchay Ruiz

Autor

Johe Santiago Quezada Fajardo

Autor

ACQUISITION AND CLASSIFICATION OF ELECTROMYOGRAPHY SIGNALS FOR HAND MOVEMENT DETECTION IN SIGN LANGUAGE

Around the world, millions of people with hearing disabilities communicate through sign language and adapt to communicate with people who don't have this condition. To provide support to sign language, this project aims to classify and recognize vowels in sign language using electromyography. Two Myoware sensors and amicrocontroller were used for data acquisition, collecting the signal from the "flexor profundo de los dedos" (deep flexor of the fingers) and "flexor largo del pulgar" (long flexor of the thumb) muscles. Then, signal processing was performed in which the data was normalized and unified for the classification of algorithms. Machine learning techniques were applied for the KNN, RF, SVM, and MLP classifiers. The results obtained showed an accuracy of 0.6035 for KNN, 0.4852 for RF, 0.3905 for SVM and 0.3550 for MLP, demonstrating that the algorithm with the best recognition rate is the KNN algorithm.

Keywords: classification algorithms; machine learning; electromyography; sign language; gesture recognition.

Omar Alvarado Cando

Director of the Degree Project



DANIEL ESTEBAN
ITURRALDE PIEDRA

Daniel Esteban Iturralde Piedra

School Coordinator

Ebbie Milena Manchay Ruiz

Author

Johe Santiago Quezada Fajardo

Author

Translated by

Ebbie Milena Manchay Ruiz

Johe Santiago Quezada Fajardo

“Adquisición y clasificación de señales de electromiografía para la detección del movimiento de la mano en lenguaje de señas”

Ebbie Milena Manchay Ruiz
Escuela de Ingeniería Electrónica
Universidad del Azuay, UDA
Cuenca, Ecuador
mile.rm@es.uazuay.edu.ec

Johe Santiago Quezada Fajardo
Escuela de Ingeniería Electrónica
Universidad del Azuay, UDA
Cuenca, Ecuador
johesanty@es.uazuay.edu.ec

Resumen—En el mundo existen millones de personas con discapacidad auditiva que se comunican a través del lenguaje de señas y se adaptan para comunicarse con personas que no tienen esta condición. Con el propósito de brindar un soporte al lenguaje de señas, este proyecto presenta como objetivo clasificar y reconocer las vocales del lenguaje de señas mediante el uso de electromiografía. Para la adquisición de datos se utilizaron dos sensores Myoware y un microcontrolador, recolectando la señal de los músculos “flexor profundo de los dedos” y “flexor largo del pulgar”. Luego, se realizó el procesamiento de señal en el cual los datos se normalizaron y unificaron para los algoritmos de clasificación. Se aplicaron técnicas de aprendizaje automático para los clasificadores KNN, RF, SVM, MLP. Los resultados obtenidos dieron una precisión de 0.6035 para KNN, un 0.4852 de RF, 0.3905 de SVM y un 0.3550 de MLP, demostrando que el algoritmo con la mejor tasa de reconocimiento es el algoritmo KNN.

Palabras clave: algoritmos de clasificación; aprendizaje automático; electromiografía; lenguaje de señas; reconocimiento de gestos.

I. INTRODUCCIÓN

La Organización Mundial de la Salud (OMS), publicó que existen alrededor de 1500 millones de personas con algún grado de pérdida de audición en el mundo [1]. De las cuales, en Ecuador se encuentran 63,191 personas con discapacidad auditiva, en donde el 54.49% son hombres y el 45.51% son mujeres, según el Consejo Nacional para la Igualdad de las Discapacidades [2]. Se puede observar que en Ecuador existe un gran número de personas con esta discapacidad y a pesar de esto, hay pocas instituciones educativas que implementan el lenguaje dactilológico [3].

Discapacidad auditiva es la persona que tiene disminución o total pérdida auditiva de uno o ambos oídos y se les dificulta identificar cualquier sonido del habla o de su entorno, por este motivo se adaptan a la ayuda de diferentes prótesis auditivas y/o el idioma de la lengua de señas [4].

El lenguaje de señas establece comunicación por un canal “gesto-viso-espacial”, siendo un factor importante en la vida diaria de las personas con discapacidad auditiva para poder

entablar comunicación y convivir en una sociedad pluricultural [5] [6].

El derecho a la comunicación es primordial para todos y la mayoría de la población no comprende la dactilología manejada por las personas sordas por el hecho de no contar con un sistema que permita detectar el lenguaje de señas mediante texto o de forma audible, siendo necesario la implementación de nuevas tecnologías para aumentar el interés por parte de personas que desconocen este lenguaje y que en un futuro se pueda eliminar esta brecha de comunicación.

Actualmente, la ciencia y la ingeniería han evolucionado en el desarrollo tecnológico, logrando grandes progresos en el área de procesamiento digital de señales biomédicas como son las señales electromiográficas (EMG), utilizándose como un beneficio para la sociedad [7].

En este proyecto, se plantea desarrollar un clasificador enfocado en el monitoreo de las señales EMG de la mano, el cual analice y detecte al realizar los movimientos de las vocales del lenguaje de señas. Además, se pretende que el proyecto pueda ser útil tanto para personas con discapacidad auditiva como para personas que no dominan ese mecanismo de comunicación y que deseen aprender o mejorar su conocimiento en el lenguaje de señas.

Este artículo está organizado de la siguiente manera: La sección II presenta los trabajos relacionados, el cual se realizó mediante una investigación sistemática con el método PRISMA. Luego, la sección III describe los conceptos básicos para entender el trabajo. En la sección IV, se explica el procedimiento de cada etapa para llegar a la clasificación de las vocales. Los resultados obtenidos se muestran en la sección V. Por último, el capítulo VI, se encuentran las conclusiones y trabajos futuros

II. ESTADO DEL ARTE

A. Investigación sistemática mediante el método PRISMA

La investigación del estudio para el estado de arte se lo realizó mediante la declaración PRISMA (Preferred Reporting Items for Systematic reviews and Meta-Analyses), el cual

recopila y sintetiza el estado de conocimiento en un área determinada para abordar la pregunta formulada [8] [9]. Las preguntas planteadas para la investigación sistemática son:

- ¿Se puede reconocer los gestos de la mano utilizando electromiografía?
- ¿Qué técnicas son utilizadas para el reconocimiento del lenguaje de señas?

a. **Búsqueda de literatura**

En la investigación se utilizaron los términos más relevantes relacionados a las preguntas formuladas y su búsqueda se hizo en los idiomas inglés y español. En los estudios encontrados se analizó y verificó el título, el resumen, la metodología y la conclusión.

Las palabras claves que se usaron para la búsqueda de información se indican en la siguiente tabla.

Tabla 1. Búsqueda de palabras clave.

Búsqueda de palabras clave
“electromiografía” y “reconocimiento de gestos”
“electromiografía” y “lenguaje de señas”
“reconocimiento de gestos” y “lenguaje de señas”

Las plataformas académicas de búsqueda se realizaron en: IEEE Xplore, PubMed, Scopus Scielo.

Para la búsqueda se utilizó la fórmula: (electromyography) AND (gesture recognition) AND (sign language) NOT (prosthesis)

b. **Criterios de búsqueda**

Se tomó en cuenta los siguientes criterios:

- **Título:** referente al tema de reconocimiento de gestos mediante EMG.
- **Idioma:** artículos escritos en español e inglés.
- **Año de publicación:** se incluyen los artículos desde el año 2017 hasta la actualidad.
- **Criterios de inclusión:** se incluyeron los artículos relacionados con el reconocimiento de gestos en el lenguaje de señas y relacionados con la tecnología de EMG.
- **Criterios de exclusión:** se excluyeron los artículos que utilizan otro método distinto a la EMG y los trabajos concernientes a las prótesis.

c. **Estrategia de extracción de datos**

Los artículos se escogieron de acuerdo con los datos relacionados a las preguntas formuladas, el título del documento, año de publicación, resumen y conclusión.

Analizando cada uno de los datos de los documentos, se elaboró un diagrama (Figura 1) del proceso para la identificación de los estudios incluidos en la investigación sistemática.




Figura 1: Diagrama de flujo del proceso de identificación de estudios mediante el método PRISMA.

B. **Resultado de la búsqueda sistemática**

Las aplicaciones de la electromiografía de superficie (sEMG) comúnmente son empleadas para el diagnóstico médico, sin embargo, con el avance tecnológico se ha logrado diversos progresos en el campo biomédico como controlar prótesis electrónicas, dispositivos de rehabilitación, investigaciones clínicas, entre otros. Dándose varias investigaciones que apoyan el desarrollo de dispositivos y aplicaciones para ayudar a personas con discapacidad o sin ella [7].

Los siguientes estudios en gran parte se enfocan en solucionar un problema social como es el de las personas sordas al no poderse comunicar con facilidad con personas oyentes.

En los trabajos [10] y [11], utilizaron el brazalete Myo Armband para reconocer el lenguaje de señas turco (TID), para esto siguieron las siguientes etapas: procesamiento de la señal, extracción de las características y clasificación de la señal. En [10] utilizaron el algoritmo de clasificación Random Forest (RF), con una precisión de validación cruzada del 78%, y en [11], para el reconocimiento de gestos se compara los algoritmos clasificadores K-Nearest Neighbors (KNN), Support Vector Machine (SVM) y Artificial Neural Network (ANN), mostrando como resultado que la mejor tasa de

reconocimiento es el algoritmo SVM con una precisión de 87%.

El artículo [12], tiene como objetivo reconocer las letras del alfabeto del lenguaje de señas irlandesa (ISL), utilizando el brazalete Myo con 12 sujetos de prueba. La metodología consistió en obtener la señal para procesarla y continuamente extraer sus características. Luego, para la clasificación emplearon varias técnicas de aprendizaje automático, obteniendo un mejor resultado en el modelo RF con una precisión del 78%.

Los estudios [13], [14] y [15], tuvieron como objetivo el de reconocer el lenguaje de señas brasileño mediante el brazalete Myo. En [13], se capturó la señal de los sujetos de prueba, para posteriormente, analizar, procesar y clasificar la señal con los algoritmos KNN y SVM, teniendo una precisión de 81,493% con KNN y 89,8911 % de SVM. Igualmente, en [14], con el fin de clasificar los gestos de la mano realizaron tres etapas: segmentación de la señal, extracción de características y reconocimiento de gestos con el clasificador RF, logrando resultados de una precisión del 99%. En cambio, para el estudio [15], utilizaron el algoritmo de clasificación Multi-Layer Perceptron (MLP), en el cual obtuvieron una precisión de 91,3% en el entrenamiento y 81,6% en la prueba.

Los sistemas propuestos en [16], [17] y [18], se basaron en múltiples sensores sEMG e implementaron el algoritmo de clasificación SVM para el reconocimiento de gestos del lenguaje de señas indio. En [16], obtienen la señal para preprocesarla y segmentarla, después, extraen las características y clasifican la señal. Al concluir con su trabajo, consideraron que entre tres y cuatro sensores sEMG son suficientes para el sistema. Por otra parte, el estudio [17] consiste en que el sujeto realice un gesto con la mano para compararlo en la base de datos y convertirlo en una señal de voz, obteniendo resultados con una precisión de 91,1%. En el trabajo [18], para la extracción de características compararon los momentos centrales temporales y espectrales, posteriormente, con la clasificación se evidenció que los momentos espectrales superan a los momentos temporales con una precisión de 90,1% y 82,1% respectivamente.

En [19] y [20], proponen un sistema adaptable para reconocer el lenguaje de señas americano (ASL) basados en EMG. En el estudio [19], recopilan datos de tres sujetos usando sensores sEMG portátiles, para el reconocimiento propusieron utilizar los métodos ANN y SVM, los cuales se compararon con Hidden Markov Model (HMM), obteniendo resultados de precisión con un 85,90% para HMM, 85,56% SVM y el más alto ANN con 93,79%. Por el contrario, en [20] se enfocaron en reducir la complejidad computacional, el espacio y la precisión para el reconocimiento de gestos, su metodología constó en captar la señal EMG mediante el brazalete Myo y utilizaron el clasificador SVM, en donde obtuvieron una reducción de la dimensionalidad y con mayor velocidad de derivación del modelo.

En los estudios [21], [22], [23] y [24], propusieron sistemas interactivos para el reconocimiento del lenguaje de señas Chino (CSL), para esto capturaron la señal por medio del brazalete Myo, seguidamente, procesaron la señal, la segmentaron, extrajeron sus características y la clasificaron. En [21] utilizaron el modelo SVM, teniendo un resultado de precisión del 98,12%. En [22] y [23] llevaron a cabo la clasificación con el algoritmo ANN, consiguiendo una precisión de 88,7% y 94,9% respectivamente. Así mismo, en [24], propusieron un modelo codificador-decodificador basado en multi-channel Convolutional Neural Network (CNN), teniendo una tasa de error de 10,8 % y una validación de tiempo de 1,1 segundos para reconocer una oración con 4 palabras de signos. En cambio, en el artículo [25] para CSL, obtuvieron los datos de 8 sensores portátiles sEMG y su clasificación se realizó con la comparación de los algoritmos RF, ANN y SVM. Los resultados obtenidos dieron una precisión de 92,56% para ANN, un 94,68 de SVM y un 95,48% de RF, demostrando que es el más estable en el reconocimiento.

Los trabajos [26] y [27], adquieren la señal mediante el brazalete Myo y emplean el modelo CNN para el reconocimiento de gestos de la mano. En [26], para el reconocimiento del lenguaje de señas coreano obtienen como resultado una precisión de 99,13% en CNN sin abandono y 98,1% de CNN con abandono. Igualmente, en [27], tuvieron un resultado de 97,5% de precisión.

En el estudio [28], se propuso reconocer el lenguaje de señas italiano mediante el brazalete Myo, lo implementaron con el mismo sujeto haciendo que realice 30 gestos y adquiriéndolos en una ventana de tiempo de 2 segundos, teniendo un resultado total de 780 muestras.

III. MARCO TEÓRICO

Para determinar cómo se generan las señales bioeléctricas mediante la EMG, se debe comprender las definiciones básicas sobre el sistema muscular del lugar en el cual se va a trabajar a lo largo del proyecto, en este caso, los conceptos que trae consigo el movimiento de los dedos.

Sistema Muscular: Está integrado por los músculos esquelético, liso y cardíaco, los cuales presentan control voluntario o involuntario para provocar movimiento. El músculo esquelético representa la mayor parte del tejido muscular [29] [30].

Músculos del antebrazo: Los músculos son órganos formados por fibras musculares [31]. La función del músculo es contraerse y estirarse, para poder realizar movimientos, fuerza y funciones vitales [32]. Están distribuidos por músculos en compartimientos anterior o flexores-pronadores y posterior o extensores-supinadores del antebrazo, subdividiéndose en cuatro capas superficial y profunda [33].

Músculos que intervienen en el movimiento de la mano

Músculo flexor profundo de los dedos: Su función anatómica es flexionar todas las articulaciones de los dedos y ayuda a la flexión de la muñeca [34].



Figura 2: *Músculo flexor profundo de los dedos* [33].

Músculo flexor largo del pulgar: Su función es flexionar el pulgar en la articulación interfalángica y apoya a la flexión de la muñeca [34].



Figura 3: *Músculo flexor largo del pulgar* [33].

Electromiografía

La EMG tiene la finalidad de captar, registrar y analizar la actividad de la señal eléctrica producida por los músculos, puesto que al momento que se contrae el músculo, se origina un impulso eléctrico que es producido por el nervio que lo controla [35]. Las señales EMG son obtenidas mediante un circuito electrónico y un software [36]. Tomando en cuenta que el nervio no debe estar afectado por ninguna patología, enfermedad o comprimido ya que el funcionamiento del impulso eléctrico transmitido se vería afectado variando sus características [35].

El movimiento que genera una persona es el resultado de la acción dirigida por el cerebro, sistema nervioso y sistema muscular, ya que al instante de actividad muscular el cerebro envía una señal al sistema nervioso central y periférico, utilizando fibras nerviosas para llegar a la unidad motora (UM) [36]. La UM (Figura 4), es el conjunto del axón de una neurona motora y las fibras musculares que determinan el control, de manera que las fibras nerviosas se encargan de transmitir impulsos eléctricos a la motoneurona [35] [37]. La señal EMG registrada por la contracción del músculo está constituida por varios potenciales de unidad motora (PUM),

considerando que entre más grande es el tamaño del músculo, se tendrá mayor cantidad de UM [36] [38].




Figura 4: *Unidad motora* [39].

Como se mencionó, el impulso eléctrico es enviado desde la motoneurona que son neuronas encargadas de producir estímulos para incitar la contracción del músculo. La unión fibromuscular canaliza el impulso eléctrico partiendo de las fibras nerviosas a las fibras musculares mediante la sinapsis que emite neurotransmisiones unidos a receptores, los cuales liberan un potencial de acción [32].

El potencial de acción es una onda de descarga eléctrica que recorre la membrana celular y modifica la distribución de carga eléctrica. Para comprender la sinapsis, hay que considerar la diferencia de potencial entre la parte interna y la parte externa de la membrana de la célula muscular (generalmente de -70 mV) [40].

El potencial de acción lo componen tres fases (Figura 5): la despolarización que es cuando el potencial de membrana decrece debido al intercambio de iones, la siguiente fase es la repolarización de la membrana y por consiguiente se encuentra el período de hiperpolarización hasta alcanzar el estado de reposo, estas fases originan un campo eléctrico que es detectado por los electrodos. Para cada campo eléctrico la suma, en tiempo y espacio, es conocida como potencial de acción de la unidad motora (PAUM), la forma va a depender del número de fibras musculares y del cambio temporal de los picos musculares individuales [40] [41] [42].




Figura 5: *Diagrama de las fases del potencial de acción* [40].

Electromiografía superficial

La EMG superficial (EMGs) proporciona el análisis de las señales eléctricas y mide el potencial eléctrico de la superficie de la piel, originado a causa de la contracción y relajación muscular al momento de la despolarización de la membrana muscular, registrando la variación del potencial de acción de las UM. El voltaje es detectado por medio de electrodos superficiales colocados en la piel, indicando cuándo el músculo está en movimiento o mantiene una posición [43]. La EMGs es un método no invasivo el cual puede ser manejado por personal no médico ya que no tiene riesgos sobre el paciente [40].

Características de las señales de EMG

Las señales EMG muestran datos aleatorios dependiendo del tiempo finito y su amplitud puede variar de 0 a 10 mV (pico a pico) y el ancho de banda entre un rango de frecuencias de 0 a 500 Hz con un máximo espectral entre 50 a 150 Hz [44] [40].

Electrodos

Electrodo es un dispositivo conductor eléctrico el cual permite detectar actividad bioeléctrica interna del cuerpo humano [40] [36]. Su función es convertir las corrientes iónicas producidas por el cuerpo en corrientes electrónicas [45]. Los tipos de electrodos más comunes son dos: electrodos intramusculares o aguja y electrodos superficiales o de contacto.

Electrodos intramusculares: Es un método invasivo en donde se introduce al electrodo a través de la piel. Siendo un procedimiento más complejo de manejar, el cual se necesita de un profesional médico para su uso. La ventaja es que puede eliminar la impedancia de la piel y obtener una señal más precisa [45].

Electrodos superficiales: Es un método no invasivo para detectar y medir la señal bioeléctrica de la superficie de los músculos [36]. Estos electrodos disminuyen los potenciales de corriente continua y el ruido del ambiente, sin embargo, pueden introducir ruido a la señal medida ya que presentan una alta impedancia de entrada. Además, la calidad de la señal EMG va a depender de la forma, tamaño, material, distancia entre cada polo, su diámetro y otras características del electrodo, para que la lectura de la señal sea más estable y con menor ruido se suele utilizar un gel conductor en el contacto electrodo-piel [36] [45] [46].

Sensor muscular

Sensor Myoware: La placa de adquisición de datos del sensor muscular Myoware se utiliza para registrar la actividad eléctrica producida por los músculos del antebrazo [47] [48]. Las dimensiones del dispositivo son 2,1" x 0,8", sujetándose a

la piel del paciente mediante electrodos, el dispositivo tiene una ganancia ajustable y su voltaje de funcionamiento es de 2,9 V a 5,7 V [49]. Adicionalmente, es un sensor que contiene un circuito amplificador, el cual amplifica la señal EMG detectada. También, posee una señal de filtrado con un filtro pasa bajo con una frecuencia de corte de 1,97 Hz para las señales ruidosas y un circuito rectificador para evitar que la señal no promedie a cero [47].

Microcontrolador

Arduino Uno: Es un microcontrolador basado en ATmega328P y contiene 14 pines de entrada/salida [50]. Además, transforma la señal analógica a una señal digital para procesar los datos [47].

Aprendizaje supervisado

Utiliza un conjunto de datos etiquetados para el entrenamiento de algoritmos que clasifiquen datos o realicen predicciones de forma precisa con base en observaciones pasadas [51].

Clasificación: se emplea un algoritmo para valores de respuesta categóricos, en donde los datos se pueden dividir en clases específicas [51].

Algoritmos de clasificación

K-Nearest Neighbors (KNN): Es un clasificador no paramétrico basado en instancias, en donde cada instancia etiquetada en el entrenamiento se define como $\{x_i, y_i\}$, que representa el valor del atributo. Su predicción se basa en medir la distancia entre el objeto de prueba y los datos de entrenamiento. En el momento que k se establece en uno, al objeto de prueba se le asignan la clase del conjunto de entrenamiento más cercano. El resultado será mayor a medida que se consigan más muestras [11] [52] [53].

Support Vector Machine (SVM): Tiene como objetivo encontrar un hiperplano con el margen más amplio para la separación de dos clases diferentes de datos, para ello, se calcula la posición del objeto de prueba con respecto al hiperplano y se le asigna la clase. Tomando en cuenta que solo se puede encontrar hiperplanos en donde se permita la separación lineal en un espacio de características de alta dimensión [19] [54].




Figura 6: Hiperplano de margen para SVM [54].

Random Forest (RF): Es un algoritmo de aprendizaje automático, el cual se compone de un conjunto de árboles de decisión para aumentar la exactitud del modelo de clasificación. Los algoritmos de RF tienen tres hiperparámetros: el tamaño del nodo, la cantidad de árboles y la cantidad de características muestreadas [55] [56].

Multilayer Perceptron (MLP): es una red neuronal caracterizada por su organización en capas de celdas separadas, teniendo la capacidad de resolver problemas de clasificación y regresión. Además, evita las conexiones “hacia atrás” ya que ninguna salida neuronal constituye una entrada para las neuronas de la misma capa [57].

IV. METODOLOGÍA

En el diagrama de bloques (Figura 8), se visualiza los principales pasos que se realizaron en el proyecto. Para la toma de datos, que se llevó a cabo con una población de 15 sujetos entre las edades de 18 a 30 años, los cuales no presentaban ninguna afección física, además, tuvieron una inducción para el aprendizaje de las vocales del lenguaje de señas (Figura 7), en el cual, se les indicó la posición, orientación y señal a realizar con la mano. Al momento de adquirir los datos, se seleccionaron los músculos en los cuales se colocaron los sensores Myoware para obtener la señal EMG.

Luego, se graficaron los datos recolectados para una adecuada detección de características y su tratamiento. Por último, se utilizaron técnicas de aprendizaje automático con el fin de clasificar las vocales.




Figura 7: Vocales del lenguaje de señas.




Figura 8: Diagrama de bloques del sistema principal.

A. Adquisición de datos

a. Selección de los músculos para obtener la señal EMG

Tras lo analizado y estudiado anteriormente, para el proyecto se eligieron los músculos “*flexor profundo de los dedos*” (Figura 2) y “*flexor largo del pulgar*” (Figura 3), puesto que se adecúan de mejor manera al movimiento que realiza la mano en la ejecución de las vocales del lenguaje dactilológico.

b. Colocación de los electrodos

Se utilizaron electrodos superficiales, los cuales deben ser colocados entre la zona de intervención y la inserción del tendón con una adecuada comprensión del músculo [34]. Hay que tener en cuenta que se debe tener una buena preparación

de la superficie de la piel en donde se van a colocar los electrodos para tener mejores resultados, teniendo en cuenta esto, a cada persona se le limpió la zona del antebrazo, con alcohol, en donde se iba a trabajar.

Una fisioterapeuta capacitó al equipo de trabajo para la correcta colocación de los electrodos de plata/cloruro de plata (Ag/AgCL) en la posición de los flexores mencionados anteriormente (Figura 9). Igualmente, se consideró que el sujeto estuviese con una prenda holgada, para que no dificulte el movimiento del antebrazo.




Figura 9: Posicionamiento de los electrodos en el antebrazo.

c. Adquisición de señales EMG

En la adquisición de datos se utilizaron dos sensores Myoware, los cuales están conectados al microcontrolador en las entradas analógicas A0 (flexor profundo de los dedos) y A1 (flexor largo del pulgar) como se muestra en la Figura 10.




Figura 10: Conexión de los sensores Myoware con el microcontrolador.

Para la recolección de datos (Figura 11), se tomó en cuenta realizar pruebas anticipadas de dos sujetos con el fin de visualizar el tiempo necesario que se demora en ejecutar el movimiento de la mano por cada vocal. Considerando lo anterior, se propuso un tiempo adicional en caso de que se presente algún inconveniente. Adicionalmente, se estimó un tiempo de espera entre cada iteración para el descanso del sujeto y se creó una marca con el fin de visualizar la iteración correspondiente.

Así mismo, se comprobó la obtención de una adecuada señal antes de empezar a recolectar los datos.




Figura 11: Diagrama de flujo para la recolección de datos.

Con el objetivo de crear un archivo se implementó un código en Python (Figura 12), en el que se efectuó la lectura y decodificación del puerto serial, en el cual, se eliminó el tiempo de espera para guardar los datos relevantes. Esto se realizó debido a que, el microcontrolador no permitía crear archivos.



Figura 12: Diagrama de flujo para la creación de archivos.

B. Procesamiento de señal

a. Análisis y depuración de las señales

Para una mejor comprensión de los datos adquiridos, se analizó de manera gráfica (Persona-Letra-Vocal-Iteración), teniendo en cuenta que cada persona realizó 21 iteraciones por cada vocal. En la Figura 13 se visualizan dos señales correspondientes al flexor profundo de los dedos (Sensor1) de “color azul” y al flexor largo del pulgar (Sensor2) de “color naranja”.




Figura 13: Representación gráfica de las vocales A-E-I-O-U respectivamente.

Una vez que se graficó y analizó las imágenes provenientes de los datos recolectados, se categorizó de manera visual para proceder a hacer la debida depuración de las señales incoherentes, ya sea por ruido, perturbaciones u otras fallas que se presentaron al momento de la recolección de datos.

b. Tratamiento y normalización del dataset

Las imágenes ayudaron al tratamiento de las señales, se delimitó el número de datos por iteración a 239. Luego, se normalizaron los datos entre 0-1 debido a que cada sensor tenía una ganancia distinta, logrando que la ganancia no sea un factor que varíe los datos. También, se establecieron dos

columnas ("letra", "Seq"), en la que "Seq" representa la secuencia para delimitar cada iteración correspondiente dependiendo de la persona e iteración ("Marca"). Por último, se creó un archivo "datos .csv" con todos los cambios realizados.

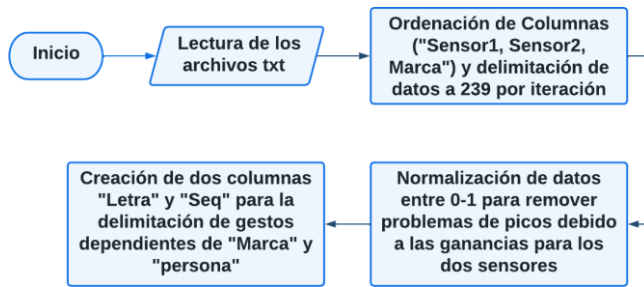


Figura 14: Diagrama de flujo de la normalización de datos.

C. Aprendizaje automático

a. Clasificación y reconocimiento de cada vocal

Se propuso utilizar los algoritmos de clasificación: KNN, SVM, RF y MLP para hacer una comparación de qué método tenía una mejor precisión. Todos estos algoritmos se implementaron utilizando la programación de Python y el dataset creado anteriormente.

En el ingreso de los datos a los algoritmos de clasificación, se modificaron los valores, en donde se disminuyó el número de filas de 405.344 a 1696, ya que la bandera que delimitaba cada secuencia "Seq" se representaría por cada fila, quedándose solo la columna de la "letra" y los datos de los sensores.

V. RESULTADOS

Se compararon los rendimientos de KNN, SVM, RF y MLP, esto se visualizó por medio del rendimiento general y rendimiento de cada vocal.

Primero, se obtuvo la matriz de confusión a través de los valores conocidos ("testY") y los valores de salida ("predY") del clasificador. Además, con las métricas de evaluación (Tabla 2), se pudo ver la precisión, el recall, Fscore y support por vocal.

Tabla 2: métricas de evaluación [58].

Precisión	Es la relación entre las instancias positivas correctamente clasificadas y las predicciones etiquetadas como positivas.
Recall (Sensibilidad, Exhaustividad)	Es la cantidad de elementos identificados, cuyo estado real sea definido como positivo.
Fscore (Medida F1)	Permite la combinación en un solo valor de la precisión con recall.
Accuracy (Exactitud)	Es la proporción de aciertos en el modelo de clasificación.

a. Resultados de KNN

Mediante Python y Scikit Learn (sklearn), el KNN se parametrizó utilizando la distancia euclidiana con parámetro $p=2$, ya que está limitada a vectores de valor real. También, "k" asumió el valor de 1, en el que se le asigna a la instancia la misma clase que el vecino más cercano. Así mismo, se representó la matriz de confusión para "k=1", en donde se puede ver en la diagonal principal el número de aciertos por clase y en sus otras celdas el número de veces erróneas. Llegando a tener una precisión de 0.6035.




Figura 15: Matriz de confusión de KNN.

Observando la matriz de confusión, para el algoritmo KNN, las tasas de error más altas se encontraban en las clases a "i" y "o".

b. Resultados de RF

Se hizo con un tamaño de submuestra (max_depth=7), el cual representa el tamaño la profundidad máxima del árbol, obteniendo una precisión de 0.4852.




Figura 16: Matriz de confusión de RF.

En la matriz de confusión, para el algoritmo RF, la tasa de error más alta se encontraba en la clase "e".

c. Resultados de SVM

Se ejecutó el algoritmo SVM con un parámetro (gamma='auto'), de acuerdo con el conjunto de entrenamiento. Su precisión es 0.3905.




Figura 17: Matriz de confusión de SVM.

En la matriz de confusión, para el algoritmo SVM, la tasa de error más alta se encontraba en la clase “i”.

d. Resultados de MLP

En el algoritmo MLP se definieron los parámetros: el optimizador (solver = 'lbfgs'), el término de regularización para prevenir los sobreajustes (alpha = 1e-5) y la representación de capas ocultas (hidden_layer_sizes = (15,)). El algoritmo tuvo una precisión de 0.3550.




Figura 18: Matriz de confusión de MLP.

En la matriz de confusión, para el algoritmo MLP, la tasa de error más altas se encontraba en la clase “o”.

Además, en la Tabla 3 se presenta un resumen de las métricas de evaluación de la matriz de confusión. De acuerdo con los resultados, la relación de precisión más alta se presenta en la clase “u” para KNN, mientras que para los otros algoritmos se da en la clase “i”. En la relación recall más alta es en la clase “a” de KNN y para el resto es en la clase “u”. Por último, en la relación Fscore la clase “u” es la más alta para todos los algoritmos.

Tabla 3: Métricas de evaluación de la matriz de confusión.

		A	E	I	O	U
Precisión	KNN	0.5122	0.6154	0.6429	0.5588	0.7407
	RF	0.4222	0.4815	0.6087	0.5385	0.4583
	SVM	0.3056	0.4062	0.4500	0.3929	0.4151
	MLP	0.3000	0.2895	0.4286	0.4167	0.3846
Recall	KNN	0.7241	0.6667	0.4865	0.5000	0.6897
	RF	0.6552	0.3611	0.3784	0.3684	0.7586
	SVM	0.3793	0.3611	0.2432	0.2895	0.7586
	MLP	0.4138	0.3056	0.3243	0.2632	0.5172

Fscore	KNN	0.6000	0.6400	0.5538	0.5278	0.7143
	RF	0.5135	0.4127	0.4667	0.4375	0.5714
	SVM	0.3385	0.3824	0.3158	0.3333	0.5366
	MLP	0.3478	0.2973	0.3692	0.3226	0.4412

En la Tabla 4, se muestra el rendimiento general de cada uno de los algoritmos de clasificación, siendo el KNN con la mayor precisión y MLP con la menor precisión.

Tabla 4: Precisión de los clasificadores.

	Precisión
KNN	0.603550
RF	0.485207
SVM	0.390533
MLP	0.355030

VI. CONCLUSIÓN Y TRABAJOS FUTUROS

Al haber realizado una investigación sistemática de cómo detectar las señales EMG en los distintos buscadores académicos (Figura 1), se encontró diversos artículos con información relevante para el desarrollo del proyecto. Para la adquisición de las señales, se tuvo en consideración los distintos factores que influyeron en la precisión del reconocimiento, en este caso, los electrodos no fueron específicamente para sEMG por falta de accesibilidad. Otros de los factores tomados en cuenta fueron: la fisiología de los músculos, tamaño del antebrazo, grosor de la capa de grasa y la actividad física. Una vez adquirida la señal, se creó un dataset, unificando todos los archivos y normalizando los datos entre 0-1 debido a que las ganancias de los sensores no son fijas. En la clasificación se extrajeron las características de la señal EMG en donde se compararon los diferentes clasificadores indicados en la Tabla 4, se obtuvo como resultado que el método KNN tiene una mejor precisión con 0.60.

En un trabajo futuro se podría seguir desarrollando nuevos métodos para extender los gestos del lenguaje de señas como es el abecedario o hasta palabras, para esto, se puede implementar más dispositivos electrónicos u otras tecnologías que permitan un sistema portátil de reconocimiento en tiempo real y se pueda transcribir automáticamente de forma audible.

VII. REFERENCIAS

- [1] Organización Mundial de la Salud, “Sordera y pérdida de la audición”, el 2 de marzo de 2021. <https://www.who.int/es/news-room/fact-sheets/detail/deafness-and-hearing-loss> (consultado el 13 de noviembre de 2022).
- [2] “Comunidad sorda en Ecuador: Un mundo de señas, silencio y lucha”, *El Universo*, el 29 de septiembre de 2018. <https://www.eluniverso.com/noticias/2018/09/29/nota/6977300/ecuador-comunidad-sorda-mundo-senas-silencio-lucha> (consultado el 10 de agosto de 2022).

- [3] J. J. Ureta Andrade y M. M. Donoso Cedeño, “Lengua de Señas Ecuatoriana (Lsec) como Herramienta de Inclusión en Educación Especializada”, *Dominio de las Ciencias*, vol. 8, núm. 2, p. 10, 2022.
- [4] S. D. Romero Cano, “El diseño de producto digital como una herramienta de apoyo para mejorar la comunicación de las personas con discapacidad auditiva”, bachelorThesis, Universidad Técnica de Ambato. Facultad de Diseño y Arquitectura. Carrera de Diseño Gráfico Publicitario, 2021. Consultado: el 17 de noviembre de 2022. [En línea]. Disponible en: <https://repositorio.uta.edu.ec:8443/jspui/handle/123456789/32143>
- [5] C. A. B. Sepúlveda, *La construcción de lo común. Cultura Sorda e Interculturalidad: Metáforas y Lengua de Señas para la Interculturalidad: una mirada al cuerpo del lenguaje*. Editorial Académica Española, 2012.
- [6] C. A. Hernandez Suarez, J. L. Pulido, y J. E. Arias, “Las tecnologías de la información en el aprendizaje de la lengua de señas”, ene. 2015, Consultado: el 17 de noviembre de 2022. [En línea]. Disponible en: <https://repositorio.unal.edu.co/handle/unal/65708>
- [7] M. Yasen y S. Jusoh, “A systematic review on hand gesture recognition techniques, challenges and applications”, *PeerJ Comput Sci*, vol. 5, p. e218, sep. 2019, doi: 10.7717/peerj-cs.218.
- [8] “Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas”, *Revista Española de Cardiología*, vol. 74, núm. 9, pp. 790–799, sep. 2021, doi: 10.1016/j.recesp.2021.06.016.
- [9] “Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas”. <https://www.revespcardiol.org/es-pdf-S0300893221002748> (consultado el 7 de septiembre de 2022).
- [10] M. Seddiqi, H. Kivrak, y H. Kose, “Recognition of Turkish Sign Language (TID) Using sEMG Sensor”, en *2020 Innovations in Intelligent Systems and Applications Conference (ASYU)*, oct. 2020, pp. 1–6. doi: 10.1109/ASYU50717.2020.9259859.
- [11] E. Kaya y T. Kumbasar, “Hand Gesture Recognition Systems with the Wearable Myo Armband”, en *2018 6th International Conference on Control Engineering & Information Technology (CEIT)*, oct. 2018, pp. 1–6. doi: 10.1109/CEIT.2018.8751927.
- [12] L. C. Galea y A. F. Smeaton, “Recognising Irish Sign Language Using Electromyography”, en *2019 International Conference on Content-Based Multimedia Indexing (CBMI)*, sep. 2019, pp. 1–4. doi: 10.1109/CBMI.2019.8877421.
- [13] A. L. Satoshi Kawamoto, D. Bertolini, y M. Barreto, “A Dataset for Electromyography-Based Dactylology Recognition”, en *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, oct. 2018, pp. 2376–2381. doi: 10.1109/SMC.2018.00408.
- [14] J. J. A. Mendes Junior, M. L. B. Freitas, D. P. Campos, F. A. Farinelli, S. L. Stevan, y S. F. Pichorim, “Analysis of Influence of Segmentation, Features, and Classification in sEMG Processing: A Case Study of Recognition of Brazilian Sign Language Alphabet”, *Sensors (Basel)*, vol. 20, núm. 16, p. E4359, ago. 2020, doi: 10.3390/s20164359.
- [15] J. J. A. Mendes Junior, M. L. B. Freitas, S. L. Stevan Jr., y S. F. Pichorim, “Recognition of Libras Static Alphabet with Myo™ and Multi-Layer Perceptron”, 2019, vol. 70, pp. 413–419. doi: 10.1007/978-981-13-2517-5_63.
- [16] R. Gupta, “On the Selection of Number of Sensors for a Wearable Sign Language Recognition System”, en *2019 Twelfth International Conference on Contemporary Computing (IC3)*, ago. 2019, pp. 1–6. doi: 10.1109/IC3.2019.8844894.
- [17] S. Goel, M. Kumar, y Yogesh, “A Real Time Sign Language Interpretation of forearm based on Data Acquisition Method”, en *2019 International Conference on Signal Processing and Communication (ICSC)*, mar. 2019, pp. 207–212. doi: 10.1109/ICSC45622.2019.8938363.
- [18] S. Sharma y R. Gupta, “On the Use of Temporal and Spectral Central Moments of Forearm Surface EMG for Finger Gesture Classification”, en *2018 2nd International Conference on Micro-Electronics and Telecommunication Engineering (ICMETE)*, sep. 2018, pp. 234–239. doi: 10.1109/ICMETE.2018.00059.
- [19] R. Fatmi, S. Rashad, y R. Integlia, “Comparing ANN, SVM, and HMM based Machine Learning Methods for American Sign Language Recognition using Wearable Motion Sensors”, en *2019 IEEE 9th Annual Computing and Communication Workshop and Conference (CCWC)*, ene. 2019, pp. 0290–0297. doi: 10.1109/CCWC.2019.8666491.
- [20] A. Shaafi, O. Salem, y A. Mehaoua, “Improving the Recognition of Sign Language from Acquired Data by Wireless Body Area Network”, en *2020 IEEE Symposium on Computers and Communications (ISCC)*, jul. 2020, pp. 1–6. doi: 10.1109/ISCC50000.2020.9219698.
- [21] M. Li, F. Wang, K. Jia, S. Zhao, y C. Li, “A Sign Language Interactive System based on Multi-feature Fusion”, en *2019 IEEE 9th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER)*, jul. 2019, pp. 237–241. doi: 10.1109/CYBER46603.2019.9066536.
- [22] Z. Zhang, Z. Su, y G. Yang, “Real-Time Chinese Sign Language Recognition Based on Artificial Neural Networks”, en *2019 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, dic. 2019, pp. 1413–1417. doi: 10.1109/ROBIO49542.2019.8961641.
- [23] M. M. Riaz y Z. Zhang, “Surface EMG Real-Time Chinese Language Recognition Using Artificial Neural Networks”, *Communications in Computer and Information Science*, vol. 1467, pp. 114–122, 2021, doi: 10.1007/978-981-16-7207-1_12.
- [24] Z. Wang et al., “Hear Sign Language: A Real-Time End-to-End Sign Language Recognition System”, *IEEE*

- Transactions on Mobile Computing*, vol. 21, núm. 7, pp. 2398–2410, jul. 2022, doi: 10.1109/TMC.2020.3038303.
- [25] S. Yuan *et al.*, “Chinese Sign Language Alphabet Recognition Based on Random Forest Algorithm”, en *2020 IEEE International Workshop on Metrology for Industry 4.0 & IoT*, jun. 2020, pp. 340–344. doi: 10.1109/MetroInd4.0IoT48571.2020.9138285.
- [26] S. Shin, Y. Baek, J. Lee, Y. Eun, y S. H. Son, “Korean sign language recognition using EMG and IMU sensors based on group-dependent NN models”, en *2017 IEEE Symposium Series on Computational Intelligence (SSCI)*, nov. 2017, pp. 1–7. doi: 10.1109/SSCI.2017.8280908.
- [27] J. Li, L. Wei, Y. Wen, X. Liu, y H. Wang, “Hand gesture recognition based improved multi-channels CNN architecture using EMG sensors”, *Journal of Intelligent and Fuzzy Systems*, vol. 43, núm. 1, pp. 643–656, 2022, doi: 10.3233/JIFS-212390.
- [28] I. Pacifici, P. Sernani, N. Falcionelli, S. Tomassini, y A. F. Dragoni, “A surface electromyography and inertial measurement unit dataset for the Italian Sign Language alphabet”, *Data in Brief*, vol. 33, 2020, doi: 10.1016/j.dib.2020.106455.
- [29] R. L. Drake, W. Vogl, y A. M. W. Mitchell, *Gray. Anatomía Básica + StudentConsult*. Elsevier Health Sciences, 2018.
- [30] J. M. Sorribas, “Esqueleto sistema articular y muscular”, El Cid Editor | apuntes, 2009. Consultado: el 29 de agosto de 2022. [En línea]. Disponible en: <https://elibro.net/es/ereader/uazuay/28191>
- [31] Virrey, “Sistema muscular”, El Cid Editor | apuntes, 2009. Consultado: el 29 de agosto de 2022. [En línea]. Disponible en: <https://elibro.net/es/ereader/uazuay/28198>
- [32] M. Fernández Martínez, “Análisis de la forma de onda de los potenciales de acción de unidad motora”, 2017, Consultado: el 17 de agosto de 2022. [En línea]. Disponible en: <https://academica-e.unavarra.es/xmlui/handle/2454/25685>
- [33] “Músculos del antebrazo”, *Kenhub*. <https://www.kenhub.com/es/library/anatomia-es/musculos-del-antebrazo> (consultado el 29 de agosto de 2022).
- [34] S. Fich y L. Marcher, *Enciclopedia del cuerpo: guía de las funciones psicomotrices del sistema muscular*. Editorial Paidotribo, 2012. Consultado: el 30 de agosto de 2022. [En línea]. Disponible en: <https://elibro.net/es/ereader/uazuay/114943>
- [35] P. A. C. Pérez, J. R. García, y J. J. R. Ibáñez, *Procesado de señales biomédicas*. Univ de Castilla La Mancha, 2007.
- [36] E. Muñoz Fabra, “Diseño e implementación de un sistema electrónico de captación de señal de electromiografía para el estudio de la fatiga muscular en condiciones estáticas y dinámicas”, Proyecto/Trabajo fin de carrera/grado, Universitat Politècnica de València, 2021. Consultado: el 17 de agosto de 2022. [En línea]. Disponible en: <https://riunet.upv.es/handle/10251/169486>
- [37] H. Curtis y A. Schnek, *Curtis. Biología*. Ed. Médica Panamericana, 2008.
- [38] G. de Blas Beorlegui, J. Fernández Lorente, y B. Ortega, “Métodos automáticos de cuantificación de potenciales de unidad motora”, *RevNeurol*, vol. 28, núm. 06, p. 616, 1999, doi: 10.33588/rn.2806.98491.
- [39] “Placa motora”, *Paradigmia*. <https://paradigmia.com/curso/locomotor/modulos/generalidades-de-los-musculos/temas/placa-motora/> (consultado el 18 de agosto de 2022).
- [40] R. Azpilcueta, “Dispositivo de adquisición de señales mioeléctricas”, Thesis, Universidad Nacional de Mar del Plata. Facultad de Ingeniería; Argentina, 2020. Consultado: el 18 de agosto de 2022. [En línea]. Disponible en: <http://rinfi.fi.mdp.edu.ar/xmlui/handle/123456789/456>
- [41] A. C. Martínez, I. Nuin, D. F. Lázaro, I. Latasa, y J. R. Falces, “Actividad electromiográfica (EMG) durante el pedaleo, su utilidad en el diagnóstico de la fatiga en ciclistas”, *Archivos de medicina del deporte: revista de la Federación Española de Medicina del Deporte y de la Confederación Iberoamericana de Medicina del Deporte*, vol. 34, núm. 180, pp. 217–223, 2017.
- [42] “Research on neurophysiological signal processing at Signals and Systems, Uppsala University”. <http://www.signal.uu.se/Research/rneurophys.html> (consultado el 18 de agosto de 2022).
- [43] S. I. Angamarca Deleg, “Mejora del sistema mecánico para movimiento de muñeca de prototipo de prótesis de mano y desarrollo de un sistema de control utilizando electromiografía de superficie para la toma de señales”, dic. 2021, Consultado: el 22 de agosto de 2022. [En línea]. Disponible en: <http://dspace.ups.edu.ec/handle/123456789/21454>
- [44] H. D. Caluguillín Pujota, “Análisis de características de señales electromiográficas para la determinación de movimientos de una mano”, 2019, Consultado: el 30 de agosto de 2022. [En línea]. Disponible en: <http://repositorio.utn.edu.ec/handle/123456789/9169>
- [45] J. Orts Blázquez, “Diseño de un sistema de adquisición de señales por electromiografía superficial para la interpretación del movimiento de la mano”, el 23 de septiembre de 2019. <https://riunet.upv.es/handle/10251/126202#> (consultado el 1 de septiembre de 2022).
- [46] M. Simão, N. Mendes, O. Gibaru, y P. Neto, “A Review on Electromyography Decoding and Pattern Recognition for Human-Machine Interaction”, *IEEE Access*, vol. 7, pp. 39564–39582, 2019, doi: 10.1109/ACCESS.2019.2906584.
- [47] Y. Omama *et al.*, “Surface EMG Classification of Basic Hand Movement”, en *2019 Fifth International Conference on Advances in Biomedical Engineering (ICABME)*, oct. 2019, pp. 1–4. doi: 10.1109/ICABME47164.2019.8940352.
- [48] S. Bhavani, K. L. Krishna, R. B. Y. Reddy, y T. Geethika, “A Low Cost Bionic Arm Based on

- Electromyography Sensor”, en *2020 7th International Conference on Signal Processing and Integrated Networks (SPIN)*, feb. 2020, pp. 896–901. doi: 10.1109/SPIN48934.2020.9070936.
- [49] ELECTROSTORE, “SENSOR MUSCULAR MYOWARE EMG – Grupo Electrostore”. <https://grupoelectrostore.com/shop/sensores/senales-bioelectricas/sensor-muscular-myoware-emg/> (consultado el 5 de enero de 2023).
- [50] “Arduino UNO | Arduino.cl - Compra tu Arduino en Línea”, el 14 de enero de 2019. <https://arduino.cl/arduino-uno/> (consultado el 6 de enero de 2023).
- [51] Mathworks, “Aprendizaje Supervisado”. <https://la.mathworks.com/discovery/supervised-learning.html> (consultado el 2 de febrero de 2023).
- [52] P. T. R. Dinger, Y. Chang, R. Pavuluri, S. S. P. el 26 de enero de 2022 P. guardar su progreso, y debe iniciar sesión en I. D. I. sesión ahora, “What is time series classification?”, *IBM Developer*, el 26 de enero de 2022. <https://developer.ibm.com/what-is-time-series-classification> (consultado el 22 de enero de 2023).
- [53] L. Ramírez, M. Ruano, C. Younes, y G. Castellanos, *Análisis de bioseñales: Enfoque técnico en el análisis clínico de señales fonocardiográficas*. Universidad Nacional de Colombia, 2016.
- [54] Mathworks, “Support Vector Machine (SVM)”, *Mathworks*. <https://la.mathworks.com/discovery/support-vector-machine.html> (consultado el 23 de enero de 2023).
- [55] “What is Random Forest? | IBM”. <https://www.ibm.com/topics/random-forest> (consultado el 23 de enero de 2023).
- [56] V. Mirjalili y S. Raschka, *Python Machine Learning*. Marcombo, 2020.
- [57] R. F. López y J. M. F. Fernández, *Las Redes Neuronales Artificiales*. Netbiblo, 2008.
- [58] C. P. Pertuz, *Aprendizaje automático y profundo en python: Una mirada hacia la inteligencia artificial*. Ediciones de la U, 2022.