

**DESARROLLO DE UN SISTEMA AUMENTATIVO DE COMUNICACIÓN MÓVIL
UTILIZANDO SEÑALES ELECTROMIOGRÁFICAS Y BIOFEEDBACK PARA PERSONAS
CON DISCAPACIDAD DEL HABLA**

**DEVELOPMENT OF AN AUGMENTATIVE MOBILE COMMUNICATION SYSTEM
USING ELECTROMYOGRAPHIC SIGNALS AND BIOFEEDBACK FOR PEOPLE WITH
SPEECH DISABILITIES**

Autores: ¹Leslie Cristina Taco Betancourt y ²Luis Geovanny Romero Mejía.

¹ORCID ID: <https://orcid.org/0000-0001-8748-8739>

²ORCID ID: <https://orcid.org/0009-0006-0037-5955>

¹E-mail de contacto: ltacob@est.ups.edu.ec

²E-mail de contacto: lromerom@ups.edu.ec

Afiliación: ^{1*2}Universidad Politécnica Salesiana, (Ecuador).

Artículo recibido: 15 de Enero del 2026

Artículo revisado: 28 de Enero del 2026

Artículo aprobado: 06 de Febrero del 2026

¹Estudiante de la carrera de Ingeniería Biomédica de la Universidad Politécnica Salesiana, (Ecuador).

²Ingeniero en Electrónica y Control. Magíster en Mecatrónica y Robótica.

Resumen

Este artículo presenta el diseño e implementación de un sistema para el reconocimiento de contracciones musculares faciales utilizando electromiografía de superficie (sEMG). El objetivo fue desarrollar una arquitectura funcional de bajo costo que registre y procese señales sEMG, incorporando biofeedback para control activo del usuario. El sistema utiliza el sensor AD8832, una fuente de alimentación dual de ± 9 V y un circuito de acondicionamiento analógico con filtro RC paso bajo (frecuencia de corte: 500 Hz) para atenuar componentes de alta frecuencia y ruido electromagnético. El sistema se integró con una placa Arduino para procesamiento en tiempo real, calculando características básicas del dominio temporal: valor medio absoluto (MAV), valor cuadrático medio (RMS) e indicador binario de activación muscular. Las características temporales complejas (longitud de onda WL y cambios de signo de pendiente SSC) se extrajeron durante entrenamiento y clasificación en Python. Estas características conformaron el vector para entrenar un clasificador SVM con kernel RBF, seleccionado por su capacidad para modelar relaciones no lineales en señales electromiográficas. El modelo fue entrenado con 251 muestras EMG correspondientes a tres

palabras: Agua, Ambulancia y Mar, alcanzando una exactitud global del 88% sobre el conjunto de prueba. Se desarrolló una aplicación web interactiva con Flask para visualización en tiempo real de la señal EMG procesada, detección de activación muscular y palabra clasificada, demostrando capacidad de procesamiento en tiempo real. Los resultados confirman que electromiografía de superficie es alternativa viable y no invasiva para desarrollo de interfaces de comunicación asistiva, estableciendo base para investigaciones futuras con ampliación de vocabulario y validación en entornos clínicos.

Palabras clave: Electromiografía superficial, Señales EMG, Reconocimiento de patrones, Arduino, Máquinas de vectores de soporte, Clasificación de señales biomédicas, Interfaz web.

Abstract

This article presents the design and implementation of a system for recognizing facial muscle contractions using surface electromyography (sEMG). The objective was to develop a low-cost functional architecture that records and processes sEMG signals, incorporating biofeedback for active user control. The system is built around the AD8832 sensor with a dual ± 9 V power supply and an analog conditioning circuit including a 500Hz

low-pass RC filter to attenuate high-frequency components and electromagnetic noise. The system was integrated with an Arduino microcontroller for real-time processing, calculating basic time-domain features: mean absolute value (MAV), root mean square (RMS), and binary muscle activation indicator. Complex temporal features (waveform length WL and slope sign changes SSC) were extracted during training and classification in Python. These features formed the vector used to train a Support Vector Machine (SVM) classifier with RBF kernel, selected for modeling nonlinear relationships in electromyographic signals. The model was trained with 251 EMG samples corresponding to three words (Water, Ambulance, Sea), achieving 88% overall accuracy on the test set. An interactive Flask web application was developed for real-time visualization of processed EMG signals, muscle activation detection, and classified words, demonstrating real-time processing capability. The results confirm that surface electromyography is a viable and non-invasive alternative for developing assistive communication interfaces, establishing a foundation for future research with vocabulary expansion and validation in clinical settings.

Keywords: Surface electromyography, EMG signals, Pattern recognition, Arduino, Support vector machines, Biomedical signal classification, Web interface.

Sumário

Este artigo apresenta o desenho e implementação de um sistema para o reconhecimento de contrações musculares faciais utilizando eletromiografia de superfície (sEMG). O objetivo foi desenvolver uma arquitetura funcional de baixo custo que registre e processe sinais sEMG, incorporando biofeedback para controle ativo do usuário. O sistema utiliza o sensor AD8832, uma fonte de alimentação dupla de ± 9 V e um circuito de condicionamento analógico com filtro RC passa-baixa (frequência de corte: 500 Hz) para atenuar componentes de alta frequência e ruído eletromagnético. O sistema foi integrado com

uma placa Arduino para processamento em tempo real, calculando características básicas do domínio temporal: valor médio absoluto (MAV), valor quadrático médio (RMS) e indicador binário de ativação muscular. As características temporais complexas (comprimento de forma de onda WL e mudanças de sinal de inclinação SSC) foram extraídas durante treinamento e classificação em Python. Estas características formaram o vetor para treinar um classificador SVM com kernel RBF, selecionado por sua capacidade de modelar relações não lineares em sinais eletromiográficos. O modelo foi treinado com 251 amostras EMG correspondentes a três palavras: Água, Ambulância e Mar, alcançando uma exatidão global de 88% sobre o conjunto de teste. Foi desenvolvida uma aplicação web interativa com Flask para visualização em tempo real do sinal EMG processado, detecção de ativação muscular e palavra classificada, demonstrando capacidade de processamento em tempo real. Os resultados confirmam que eletromiografia de superfície é alternativa viável e não invasiva para desenvolvimento de interfaces de comunicação assistiva, estabelecendo base para pesquisas futuras com ampliação de vocabulário e validação em ambientes clínicos.

Palavras-chave: Eletromiografia de superfície, sinais EMG, reconhecimento de padrões, Arduino, máquinas de vetores de suporte, classificação de sinais biomédicos, interface web.

Introducción

La comunicación es un pilar fundamental de la interacción social y el desarrollo personal. Sin embargo, condiciones neurológicas, neuromusculares o traumatismos pueden afectar la capacidad de habla, generando dependencia de Sistemas Aumentativos y Alternativos de Comunicación (SAAC) (Pinheiro et al., 2011; Naves et al., 2012). En este contexto, la señalización a través de biocomunicación se presenta como una alternativa para reducir la brecha de

comunicación, traduciendo la intención motora del usuario en comandos comprensibles. La electromiografía superficial (sEMG) ha demostrado eficacia por su bajo nivel de invasividad, costo accesible, y capacidad de captar señales musculares relacionadas con movimientos faciales y producción del habla (Salomons et al., 2025; Gowda et al., 2025). Las señales EMG faciales han sido estudiadas en reconocimiento de fonemas, habla silenciosa y control de sistemas humano-computador, demostrando su potencial en asistencia y rehabilitación (Mohd et al., 2022; Kang et al., 2025). El principal desafío en sistemas basados en EMG reside en optimizar el procesamiento en tiempo real, la inmunidad al ruido y la eficiencia computacional. Si bien el uso de redes neuronales profundas mejora el rendimiento en tareas de clasificación, estas técnicas consumen muchos recursos de datos y computación, limitando su uso en sistemas embebidos de bajo costo (Gowda et al., 2025; Sualiheen y Kim, 2025). Existe un creciente interés en enfoques híbridos que integran procesamiento ligero en hardware con clasificación en plataformas más potentes (Eddy et al., 2023; Toledo-Peral et al., 2022). El presente estudio propone el diseño y desarrollo de una arquitectura funcional de bajo costo que registre y procese señales sEMG, incorporando biofeedback para control activo del usuario. El sistema utiliza un sensor AD8832 acompañado de una unidad de acondicionamiento analógico que contiene un filtro RC paso bajo de aproximadamente 500 Hz, diseñado para suprimir el contenido de alta frecuencia y el ruido de la señal electromiográfica facial (Hasan, 2025; Ghoul et al., 2024).

Materiales y Métodos

El estudio adoptó una perspectiva cuantitativa con alcance descriptivo-experimental y diseño transversal aplicado. Se recolectaron datos en

un ambiente controlado con el propósito de medir el rendimiento funcional del sistema como prototipo para la interacción asistida por señales de los músculos faciales, sin realizar inferencias a la población. La arquitectura del sistema propuesto se estructuró en cuatro componentes fundamentales: adquisición de la señal electromiográfica, procesamiento embebido en tiempo real, clasificación automática y visualización de resultados. Esta arquitectura se justifica en la separación de la carga computacional entre el hardware embebido y el sistema de procesamiento externo, optimizando así el desempeño del sistema.

Figura 1. *Arquitectura del sistema de reconocimiento de contracciones musculares faciales basado en EMG*



La recolección de señales electromiográficas se realizó a partir de la actividad eléctrica muscular a través de electrodos de superficie situados sobre los músculos faciales. La señal EMG adquirida fue de microvoltios, por lo que fue amplificada y acondicionada por medio del módulo electromiográfico AD8832. El módulo cuenta con un amplificador diferencial con alta impedancia y una ganancia de $G \approx 1000$, lo que eleva la amplitud de la señal EMG a un nivel compatible con la entrada del convertidor analógico digital del microcontrolador. El acondicionamiento analógico contiene un filtro analógico de primer orden en el cual una resistencia y un condensador forman un sistema RC que permite el paso de señales de bajas frecuencias y atenúa la presencia de componentes de alta frecuencia y ruidos

electromagnéticos. La frecuencia de corte del filtro se determina por la siguiente relación:

$$f_c = 1/2\pi RC$$

Para la implementación física, se seleccionaron valores comerciales de $R=3.3\text{ k}\Omega$ y $C=0.1\text{ }\mu\text{F}$. Sustituyendo estos valores en la ecuación (1), se obtiene una frecuencia de corte real de:

$$f_c = 1/(2\pi(3300\Omega)(0.1 \times 10^{-6}\text{ F})) \approx 482.28\text{ Hz}$$

Esta configuración permite mitigar el ruido de alta frecuencia y prevenir el solapamiento (aliasing) antes de la etapa de digitalización. La muestra del estudio estuvo conformada por cinco participantes adultos, de los cuales tres presentaban antecedentes de discapacidad del habla y dos no registraban patologías neuromusculares diagnosticadas. Todos los participantes contaban con la capacidad de realizar contracciones musculares faciales de manera voluntaria, condición necesaria para la validación del sistema propuesto. La selección se realizó mediante un muestreo de conveniencia no aleatorio, dado que el objetivo principal del estudio fue la evaluación funcional y técnica del prototipo desarrollado (Naves et al., 2012).

Las pruebas experimentales se realizaron en un entorno controlado, aplicando criterios uniformes para la colocación de los electrodos, la recalibración del sistema y la ejecución de las contracciones musculares faciales. Se controlaron variables externas tales como la posición del usuario, el nivel de actividad previa y la proximidad a fuentes potenciales de interferencia electromagnética, con el fin de minimizar la presencia de ruido no deseado en la señal EMG adquirida. La adquisición de las señales electromiográficas se realizó utilizando un sensor electromiográfico AD8832, diseñado

para la captación no invasiva de señales musculares de superficie. La señal electromiográfica fue adquirida con una frecuencia de muestreo de 1 kHz, valor adecuado para capturar el contenido espectral relevante de las señales EMG faciales. La digitalización se realizó mediante el convertidor analógico-digital (ADC) de 10 bits del microcontrolador Arduino, con un rango de entrada de 0-5 V. El sistema de adquisición presentó una ganancia total aproximada de $G \approx 1000$, proporcionada por el módulo electromiográfico AD8832.

Figura 2. Ubicación de los electrodos EMG durante la adquisición de las señales electromiográficas faciales



El sistema de adquisición empleó tres electrodos adhesivos de superficie, configurados como electrodo activo positivo, electrodo activo negativo y electrodo de referencia. Los electrodos activos fueron colocados específicamente sobre los músculos cigomático mayor y cigomático menor, seleccionados por su participación directa en gestos faciales voluntarios y su adecuada relación señal-ruido. El electrodo de referencia se ubicó en la región retroauricular, con el fin de reducir interferencias comunes y mejorar la estabilidad de la señal adquirida. Para la alimentación del sensor AD8832 se utilizaron

dos fuentes de alimentación simétricas de ± 9 V. El microcontrolador Arduino fue alimentado mediante una fuente de 5 V, manteniendo un aislamiento funcional entre la etapa de adquisición analógica y la etapa de procesamiento digital.

La señal analógica acondicionada fue digitalizada mediante el ADC de 10 bits del microcontrolador Arduino. Posteriormente, las muestras digitalizadas fueron sometidas a un proceso de filtrado digital en tiempo real, implementado mediante un filtro de media móvil de orden $M=8$, cuyo objetivo fue atenuar componentes de ruido de alta frecuencia y suavizar la señal electromiográfica antes de la extracción de características. Una vez filtrada, la señal fue organizada en ventanas temporales de longitud fija ($N=60$ muestras), lo que permitió el cálculo eficiente de características básicas en el dominio del tiempo. Previo a cada sesión experimental se ejecutó un proceso automático de recalibración con el músculo en estado de reposo, cuyo objetivo fue estimar el nivel basal de la señal electromiográfica y compensar variaciones individuales, desplazamientos de línea base y ruido fisiológico inherente a la adquisición de señales EMG. La señal electromiográfica adquirida fue corregida mediante la sustracción del valor basal estimado, obteniéndose la señal rectificada según la siguiente expresión:

$$x_{\text{corr}}(n) = |x(n) - x_{\text{base}}|$$

donde $x(n)$ representa la señal EMG original y x_{base} corresponde al nivel basal calculado durante el estado de reposo muscular. A partir de la señal corregida, se definió un umbral de activación muscular basado en el valor medio absoluto (MAV):

$$T = k \cdot \text{MAV}_{\text{reposo}}$$

donde $k=2$ fue seleccionado de manera empírica tras pruebas preliminares, proporcionando una adecuada separación entre la actividad muscular voluntaria y las fluctuaciones de baja amplitud asociadas al ruido residual (Moon et al., 2024). Durante la etapa de procesamiento embebido en el microcontrolador Arduino se calcularon únicamente características básicas en el dominio temporal, específicamente el valor medio absoluto (MAV), el valor cuadrático medio (RMS) y un indicador binario de activación muscular. El valor medio absoluto se calculó como:

$$\text{MAV} = 1/N \sum_{n=1}^N x(n)$$

De manera similar, el valor cuadrático medio (RMS) se obtuvo mediante:

$$\text{RMS} = \sqrt{(1/N \sum_{n=1}^N x^2(n))}$$

Las características de mayor complejidad se extrajeron exclusivamente durante la fase de entrenamiento y clasificación, implementada en un entorno de procesamiento externo en Python. En esta etapa se calcularon la longitud de la forma de onda (Waveform Length, WL) y los cambios de pendiente (Slope Sign Changes, SSC) (Pinheiro et al., 2011; Eddy et al., 2023). La longitud de la forma de onda se definió como:

$$\text{WL} = \sum_{n=1}^{N-1} |x(n+1) - x(n)|$$

Por su parte, los cambios de pendiente se calcularon mediante:

$$\text{SSC} = \sum_{n=2}^{N-1} f((x(n) - x(n-1))(x(n) - x(n+1)))$$

Donde la función $f(\cdot)$ se define como:

$$f(u) = \begin{cases} 1, & \text{si } u \geq 0 \\ 0, & \text{en otro caso} \end{cases}$$

siendo θ un umbral definido para reducir la influencia del ruido en la detección de cambios de pendiente. Se utilizó una Máquina de Vectores de Soporte (SVM) con kernel de función de base radial (RBF) para clasificar los patrones musculares faciales, seleccionado por su capacidad para modelar relaciones no lineales presentes en señales electromiográficas (Gowda et al., 2025; Hasan, 2025).

Los datos fueron transformados con StandardScaler previo al entrenamiento. El conjunto de datos se dividió en entrenamiento y prueba (80/20) con muestreo estratificado para preservar la distribución de clases. La evaluación del modelo incorporó precisión global, exactitud, recall y puntuación F1. Se construyó una matriz de confusión para analizar predicciones correctas e incorrectas por clase, identificando errores específicos entre palabras y patrones de confusión. Se calculó el intervalo de confianza del 95% para la precisión global mediante aproximación normal:

$$IC_{(95\%)} = \hat{p} \pm z_{(\alpha/2)} \sqrt{(\hat{p}(1-\hat{p}))/n}$$

donde $\hat{p}$ representa la precisión observada, n el tamaño de muestra y $z_{(\alpha/2)} = 1.96$. Se desarrolló una interfaz de usuario basada en el framework web Flask, implementada en Python, con el objetivo de facilitar la interacción del usuario con el sistema de comunicación aumentativa basado en señales de electromiografía (EMG). La interfaz permitió la visualización en tiempo real de la señal EMG procesada, el nivel de activación muscular detectado y la palabra reconocida por el clasificador. Adicionalmente, la interfaz integró un mecanismo de biofeedback visual basado en el valor medio absoluto (MAV). Este mecanismo permitió al usuario observar en tiempo real la intensidad y duración de las contracciones musculares faciales realizadas,

favoreciendo el ajuste consciente del esfuerzo muscular y contribuyendo a mejorar la consistencia y reproducibilidad de los patrones de activación generados.

Los protocolos garantizaron repetibilidad de pruebas, reduciendo fatiga muscular en condiciones controladas. Antes de cada sesión se verificó la posición de electrodos y se realizó calibración con músculo en reposo. Se definieron tres palabras generadas mediante contracciones voluntarias. Cada palabra se abordó en una secuencia de adquisición con hasta tres intentos consecutivos. Cada intento consistió en contracción muscular voluntaria seguida de 30 s de descanso para minimizar superposición y permitir recuperación muscular. Cada sesión tuvo duración aproximada de 16 minutos (10 minutos de descanso, 5 minutos de contracciones), reduciendo fatiga y manteniendo calidad de señal.

Resultados y Discusión

El sistema fue entrenado y evaluado con 251 muestras EMG de tres palabras: Agua, Ambulancia y Mar. Cada muestra se obtuvo con contracciones faciales detectadas automáticamente mediante umbral MAV. El umbral se calibró por sesión individual durante fase de reposo, estableciéndose como factor multiplicativo ($k=2$) del MAV basal. En Arduino se calcularon características básicas: MAV, RMS e indicador binario de activación. En procesamiento fuera de línea se extrajeron WL y SSC, combinándose con MAV y RMS para formar el vector de características final. El conjunto de datos se dividió en entrenamiento (80%) y prueba (20%) con separación estratificada. El conjunto de prueba (51 muestras) se utilizó exclusivamente para evaluación del clasificador SVM con kernel RBF. El modelo alcanzó exactitud global del

88%. Los resultados por clase se presentan en la Tabla 1:

Tabla 1. Resultados de clasificación por palabra

Palabra	Precisión (%)	Recall (%)	F1
Agua	83	90	0.86
Ambulancia	92	85	0.88
Mar	94	88	0.91

Fuente: Elaboración propia

El intervalo de confianza del 95% para precisión global, considerando $\hat{p}=0.88$ y $n=51$, se ubicó en el rango $[0.79, 0.97]$, indicando que el desempeño se mantiene estadísticamente estable, validando la fiabilidad de los parámetros utilizados. Los resultados evidencian que características temporales simples (MAV, RMS) complementadas con descriptores de forma (WL, SSC) permitieron discriminación efectiva entre patrones musculares. El desempeño del SVM con kernel RBF confirma su capacidad para modelar relaciones no lineales en señales EMG faciales, concordando con estudios similares (Pinheiro et al., 2011; Shafiq et al., 2024). La matriz de confusión mostró comportamiento balanceado entre clases con baja tasa de errores de clasificación cruzada, sugiriendo que las características capturan adecuadamente la dinámica temporal e intensidad de activación muscular facial. Resultados comparables han sido descritos en investigaciones sobre interfaces EMG (Gowda et al., 2025; Ghoul et al., 2024).

La decisión de calcular únicamente MAV, RMS y detección de activación en el microcontrolador redujo la carga computacional y garantizó transmisión en tiempo real. La extracción de características adicionales y entrenamiento se realizaron fuera de línea, siguiendo una arquitectura distribuida ampliamente utilizada en prototipos EMG de

bajo costo (Mohd et al., 2022). La interfaz gráfica y el biofeedback visual basado en MAV facilitaron el control voluntario de contracciones musculares. La visualización en tiempo real permitió al usuario ajustar progresivamente intensidad y duración de activación, mejorando la consistencia de señal, comportamiento consistente con lo reportado en la literatura (Toledo et al., 2022). Durante el desarrollo experimental se identificaron limitaciones relacionadas con sensibilidad a interferencias electromagnéticas externas. La proximidad a dispositivos electrónicos generó incrementos no deseados en amplitud EMG, produciendo activaciones espurias, comportamiento inherente a la baja amplitud de señales de superficie (Pinheiro et al., 2011; Eddy et al., 2023). Las pruebas se realizaron en entorno controlado, minimizando fuentes de ruido y asegurando correcta colocación de electrodos y referencia a tierra adecuada, concordando con recomendaciones metodológicas para sistemas EMG aplicados a comunicación asistida (Naves et al., 2012; Moon et al., 2024). El sistema mantuvo desempeño estable bajo estas condiciones, demostrando viabilidad como prototipo funcional.

Conclusiones

Este documento presenta el diseño, implementación y evaluación de un sistema de comunicación aumentativa basado en señales EMG faciales capaz de interpretar contracciones musculares voluntarias en comandos comunicativos específicos. De los resultados mostrados, de su análisis y de su discusión, se pueden obtener las siguientes conclusiones:

- La electromiografía de superficie constituye una alternativa viable y no invasiva para el desarrollo de interfaces de

comunicación asistiva, con un desempeño del 88% de precisión global en la clasificación de tres palabras del vocabulario definido. El diseño modular del sistema permitió una integración organizada de los módulos de adquisición, procesamiento, clasificación y visualización, contribuyendo a un funcionamiento estable y reproducible del prototipo.

- La combinación de características temporales simples (MAV, RMS) computadas en tiempo real con descriptores adicionales (WL, SSC) extraídos fuera de línea demostró ser eficaz para la discriminación de patrones musculares faciales, optimizando la carga computacional del sistema embebido. La interfaz gráfica web con biofeedback visual en tiempo real mejoró significativamente la interacción usuario-sistema, permitiendo al usuario ajustar intensidad y duración de contracciones musculares y resultando en mejor consistencia de patrones de activación.
- La sensibilidad del sistema a interferencias electromagnéticas en entornos no controlados constituye una limitación inherente a los sistemas EMG de superficie, lo que resalta la importancia del adecuado acondicionamiento de señal y control del entorno de adquisición. El sistema es funcional, reproducible y técnicamente consistente como prototipo EMG de comunicación asistiva, estableciendo una base sólida para investigaciones futuras que conlleven ampliación del vocabulario, incorporación de múltiples canales electromiográficos, mejora de robustez ante ruido y validación con usuarios finales en entornos clínicos.

Referencias Bibliográficas

- Ausubel, E. (2023). A framework and call to action for the future development of EMG-based input in HCI. *Conference on Human Factors in Computing Systems - Proceedings*.
<http://dx.doi.org/10.1145/3544548.3580962>
- Ghoul, O. (2024). Design and implementation of an EMG-based communication interface for enhancing interaction with deaf individuals. *Journal of Information Sciences*, 23, 1–20.
<https://revues.imist.ma/index.php/JIS/article/view/51444>
- Gowda, H. (2025). Geometry of orofacial neuromuscular signals: Speech articulation decoding using surface electromyography. *Journal of Neural Engineering*.
- Hasan, H. (2025). A cost effective deaf-mute electronic assistant system using Myo armband and smartphone. arXiv.
<https://arxiv.org/pdf/2503.14901>
- Kang, J. (2025). A wearable silent text input system using EMG and piezoelectric sensors. *Sensors*, 25(8), 2624.
<https://www.mdpi.com/1424-8220/25/8/2624>
- Mohd, T. (2022). Multi-modal data fusion of voice and EMG data for robotic control. *IEEE 8th Annual Ubiquitous Computing, Electronics and Mobile Communication Conference (UEMCON)*, 329–333.
<http://arxiv.org/abs/2201.02237>
- Moon, K. (2024). Wireless mouth motion recognition system based on EEG-EMG sensors for severe speech impairments. *Sensors*, 24(13), 4125.
<https://www.mdpi.com/1424-8220/24/13/4125>
- Naves, E. (2012). Alternative communication system for people with severe motor disabilities using myoelectric signal control. *ISSNIP Biosignals and Biorobotics Conference: Biosignals and Robotics for Better and Safer Living (BRC 2012)*.
- Pinheiro, C. (2011). Alternative communication systems for people with severe motor disabilities: A survey. *BioMedical Engineering Online*, 10, 1–28.

<https://biomedical-engineering-online.biomedcentral.com/articles/10.1186/1475-925X-10-31>

Salomons, I. (2025). Electrode setup for electromyography-based silent speech interfaces: A pilot study. *Sensors*, 25(3), 781.

<https://www.mdpi.com/1424-8220/25/3/781>

Shafiq, U. (2024). A fusion of EMG and IMU for an augmentative speech detection and recognition system. *IEEE Access*, 12, 14027–14039.

Sualiheen, S. (2025). Emgvox-GAN: A transformative approach to EMG-based speech synthesis, enhancing clarity and efficiency via extensive dataset utilization.

Computer Speech & Language, 92, 101754.

<https://www.sciencedirect.com/science/article/pii/S0885230824001360>

Toledo, C. (2022). Virtual/augmented reality for rehabilitation applications using electromyography as control/biofeedback: Systematic literature review. *Electronics*, 11(14), 2271. <https://www.mdpi.com/2079-9292/11/14/2271>



Esta obra está bajo una licencia de **Creative Commons Reconocimiento-No Comercial 4.0 Internacional**. Copyright © Leslie Cristina Taco Betancourt y Luis Geovanny Romero Mejía.

