



**UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA**



**PREDICCIÓN DE LA POSICIÓN DE LOS DEDOS DE LA MANO A PARTIR DE
ELECTROMIOGRAFÍA SUPERFICIAL EN TIEMPO REAL**

POR

Jorge Américo Fritis Zacconi

Informe de Memoria de Título presentada a la Facultad de Ingeniería de la Universidad de Concepción
para optar al título profesional de Ingeniero Civil Biomédico

Profesor Guía
Esteban Pino Quiroga

Agosto 2025
Concepción (Chile)

© 2025 Jorge Américo Fritis Zacconi

© 2025 Jorge Américo Fritis Zacconi

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento.

Agradecimientos

Quisiera agradecer a mis padres, Jorge Fritis y Giannina Zacconi, como también a mi hermano Ignacio Fritis por su apoyo incondicional y por siempre creer en mí. Por enseñarme el valor del esfuerzo y la importancia de seguir mis sueños.

También quisiera agradecer a mi profesor guía Esteban Pino por ayudarme a lo largo de este proyecto, por su paciencia y por compartir sus conocimientos conmigo.

A Macarena Jara por su apoyo constante y tener paciencia conmigo en los momentos estresantes.

A todos los participantes del estudio por su tiempo y disposición para colaborar en esta investigación.

Resumen

La interacción entre humanos y máquinas ha evolucionado significativamente, impulsando la necesidad de interfaces más naturales y eficientes. En este contexto, la estimación de movimientos articulares a partir de señales electromiográficas (EMG) se presenta como una alternativa prometedora para el control de dispositivos robóticos y prótesis, así como para aplicaciones en rehabilitación y traducción de lengua de señas.

Este trabajo aborda el desafío de predecir las posiciones articulares de los dedos de la mano a partir de señales electromiográficas superficiales (sEMG) registradas desde la muñeca. Para ello, se desarrolló un sistema completo que incluye una pulsera impresa en 3D con cinco sensores EMG, un módulo de adquisición inalámbrico, y una interfaz gráfica que permite registrar y visualizar simultáneamente las señales musculares y los ángulos articulares validado por un sistema de visión por computadora (MediaPipe).

Se construyó una base de datos con 25 gestos realizados por 15 usuarios en 10 sesiones, incluyendo cambios en la ubicación de los electrodos en la muñeca para evaluar la robustez del sistema. Con estos datos se entrenó una red neuronal convolucional con mecanismos de atención y una arquitectura multi-ramal, donde cada rama está enfocada en un dedo específico.

El modelo obtuvo errores angulares promedio menores a 8° en condición intrausuario y correlaciones superiores a 0.75, mostrando que puede seguir la evolución del movimiento de los dedos. En condición interusuario, el rendimiento fue más bajo, aunque mejoró cuando se entrenó con datos de varios sujetos, teniendo una correlación de 0.25 y errores promedio de 10° .

Entre las conclusiones principales, se destaca que el sistema es funcional y viable para aplicaciones prácticas siempre que el modelo esté entrenado con datos del usuario o con suficiente diversidad. Además, se demostró que el modelo es sensible a la posición de la pulsera, pero esta limitación puede ser mitigada incorporando datos de entrenamiento con distintas ubicaciones.

Como proyecciones futuras, se propone mejorar la calidad de las señales utilizando sensores EMG de diseño propio, incorporar sensores inerciales para complementar la información muscular, implementar un sistema de calibración rápida para nuevos usuarios, y explorar el uso de electromiografía de alta densidad (HD-EMG) para aumentar la precisión espacial del sistema.

Abstract

The interaction between humans and machines has evolved significantly, driving the need for more natural and efficient interfaces. In this context, estimating joint movements from electromyographic (EMG) signals emerges as a promising alternative for controlling robotic devices and prosthetics, as well as for applications in rehabilitation and sign language translation.

This work addresses the challenge of predicting the joint positions of the fingers using only surface electromyographic (sEMG) signals recorded from the wrist. To achieve this, a complete system was developed, including a 3D-printed wristband with five EMG sensors, a wireless acquisition module, and a graphical interface that allows for simultaneous recording and visualization of muscle signals and joint angles, validated by a computer vision system (MediaPipe).

A database was built with 25 gestures performed by 15 users across 10 sessions, including variations in electrode placement on the wrist to evaluate the system's robustness. Using this data, a convolutional neural network with attention mechanisms and a multi-branch architecture—where each branch focuses on a specific finger—was trained.

The model achieved average angular errors below 8° and correlation values above 0.75 in intra-user evaluations, demonstrating its ability to follow finger movements over time. In inter-user evaluations, performance decreased, but improved when the model was trained with data from multiple subjects, reaching a correlation of 0.25 and average errors around 10° .

Among the main conclusions, the system proved to be functional and suitable for practical applications, provided that the model is trained either with data from the target user or with a sufficiently diverse dataset. It was also shown that the model is sensitive to the position of the wristband, although this limitation can be mitigated by including training data from different placements.

For future work, it is proposed to improve signal quality using custom-designed EMG sensors, integrate inertial sensors to complement muscle information, implement a rapid calibration system for new users, and explore the use of high-density electromyography (HD-EMG) to enhance the system's spatial precision and robustness.

Tabla de contenidos

ÍNDICE DE TABLAS.....	IX
ÍNDICE DE FIGURAS	X
CAPÍTULO 1. INTRODUCCIÓN.....	1
1.1 INTRODUCCIÓN	1
1.2 OBJETIVOS	4
1.2.1 <i>Objetivo general</i>	4
1.2.2 <i>Objetivos específicos</i>	4
1.3 ALCANCE Y LIMITACIONES	4
1.4 METODOLOGÍA.....	5
1.5 TEMARIO	5
CAPÍTULO 2. MARCO TEÓRICO	7
2.1 ANATOMÍA DEL ANTEBRAZO.....	7
2.1.1 <i>Músculos Posteriores</i>	7
2.1.2 <i>Músculos Anteriores</i>	8
2.2 MOVIMIENTOS DE LOS DEDOS	10
2.2.1 <i>Pitch (Flexión y Extensión)</i>	10
2.2.2 <i>Yaw (Abducción y Aducción)</i>	10
2.3 ELECTROMIOGRAFÍA.....	11
2.3.1 <i>Tipos de Electromiografía (EMG)</i>	12
2.3.2 <i>Procesamiento de Señales</i>	12
2.3.3 <i>Filtros</i>	13
2.4 COMPONENTES ELECTRÓNICOS	13
2.4.1 <i>Microcontrolador</i>	13
2.4.2 <i>Convertidor Análogo Digital</i>	14
2.4.3 <i>Amplificador</i>	14
2.5 REDES NEURONALES ARTIFICIALES	15
2.5.1 <i>Redes Neuronales Convolucionales Redes Neuronales Convolucionales (CNN)</i>	15

2.5.2	<i>Mecanismo de Atención</i>	16
2.5.3	<i>Redes Neuronales Residuales Redes Neuronales Residuales (ResNet)</i>	16
2.6	DISCUSIÓN	17
CAPÍTULO 3. DISEÑO DE LA PULSERA		18
3.1	MÓDULO EMG	18
3.2	PLATAFORMA DE ADQUISICIÓN Y TRANSMISIÓN	19
3.2.1	<i>Microcontrolador ESP32-S3 SuperMini</i>	19
3.2.2	<i>Transmisión inalámbrica</i>	19
3.3	POSICIONAMIENTO DE LOS SENSORES	20
3.4	ENERGIZACIÓN DEL SISTEMA	21
3.5	DISEÑO Y FABRICACIÓN DE LA CARCASA DE LA PULSERA	21
CAPÍTULO 4. CONSTRUCCIÓN DEL CONJUNTO DE DATOS		25
4.1	CAPTURA DE ÁNGULOS CON MEDIAPIPE	25
4.1.1	<i>Suavizado Temporal</i>	26
4.1.2	<i>Almacenamiento de los Datos</i>	26
4.2	INTERFAZ DE USUARIO Y SINCRONIZACIÓN	26
4.3	FORMATO Y ESTRUCTURA DE LOS DATOS	27
4.4	GESTOS REALIZADOS	28
4.5	DISCUSIÓN	29
CAPÍTULO 5. DISEÑO DEL MODELO DE REDES NEURONALES		30
5.1	PREPROCESAMIENTO DE DATOS	30
5.1.1	<i>Filtrado y Normalización</i>	30
5.1.2	<i>Interpolación y Suavizado de Ángulos</i>	30
5.1.3	<i>Segmentación en Ventanas y Etiquetado Secuencial</i>	30
5.1.4	<i>Normalización de Ángulos</i>	31
5.1.5	<i>Aumentación de Datos</i>	31
5.2	ARQUITECTURA DEL MODELO	31
5.2.1	<i>Encoder</i>	31
5.2.2	<i>Mecanismo de Atención</i>	32
5.2.3	<i>Decoder</i>	32
5.3	FUNCIÓN DE PÉRDIDA	33
5.4	PROCEDIMIENTO PARA EL ENTRENAMIENTO DEL MODELO	33

CAPÍTULO 6. RESULTADOS	35
6.1 EVALUACIÓN INTRAUSUARIO	36
6.2 EVALUACIÓN INTERUSUARIO.....	37
6.3 ANÁLISIS POR GESTOS	39
6.4 DISCUSIÓN	42
CAPÍTULO 7. DISCUSIÓN Y CONCLUSIÓN	44
7.1 DISCUSIÓN	44
7.2 CONCLUSIÓN	45
7.3 TRABAJO FUTURO	46
GLOSARIO.....	47
REFERENCIAS	48

Índice de Tablas

6-1	Resultados intrausuario	37
6-2	Resultados interusuario	39
6-3	Equivalencia entre identificadores y gestos	41

Índice de Figuras

1.1	Sensores utilizados en el sistema FingerTrak	1
1.2	Sensores utilizados en el sistema NeuroPose	2
1.3	Sensores utilizados en el sistema WETrak	3
2.1	Músculos superficiales y profundos posterior del antebrazo	8
2.2	Músculos superficiales y profundos anterior del antebrazo	9
2.3	Ángulos posibles de la mano	11
2.4	Huesos de la mano	11
3.1	Ubicación de los sensores EMG en la muñeca	20
3.2	Carcasa de la pulsera con sensores EMG	22
3.3	Vista superior de la pulsera	23
3.4	Vista inferior de la pulsera	23
3.5	Componentes electrónicos de la pulsera	24
4.1	Interfaz gráfica del software para la captura de datos	27
4.2	Gestos Realizados para la Adquisición de Datos	28
5.1	Esquema de la arquitectura del modelo	32
6.1	Interfaz de predicción en tiempo real	35
6.2	Reconstrucción de letras de la lengua de señas chilena (LSCh)	36
6.3	Resultados intrausuario	37
6.4	Resultados interusuario con modelo de un sujeto	38
6.5	Resultados interusuario con modelo multiusuarios	39
6.6	Error promedio por gesto	42

Capítulo 1. Introducción

1.1 Introducción

El seguimiento de movimientos de los dedos mediante sensores de Electromiografía (EMG) ha cobrado relevancia en campos como la interacción humano-computador, la robótica, la salud inteligente y la rehabilitación [1, 2]. Capturar la postura de la mano en tiempo real permite controlar prótesis, facilitar terapias motoras o traducir gestos de la lengua de señas a texto o voz [3]. A diferencia de los métodos basados en cámaras o sensores sin contacto, el uso de EMG presenta varias ventajas: elimina las preocupaciones de privacidad, reduce los costos computacionales y no depende de condiciones ambientales como la iluminación o la oclusión de objetos [4, 5].

Dentro de las soluciones basadas en visión, herramientas como MediaPipe de Google o dispositivos como Leap Motion han sido ampliamente utilizadas para capturar poses de la mano de manera tridimensional [6]. No obstante, su eficacia se ve reducida en entornos no controlados, ya que requieren visibilidad directa de las manos, son sensibles a cambios en la iluminación y no se adaptan fácilmente a escenarios de movilidad. Por otro lado, sistemas como FingerTrak, que utilizan sensores térmicos montados en el antebrazo distal, ofrecen una alternativa sin contacto, pero su precisión depende fuertemente de la temperatura ambiente y de la calibración del entorno [7].

En la Figura 1.1 se ilustran los sensores utilizados en el sistema FingerTrak.




Figura 1.1: Sensores térmicos utilizados en el sistema FingerTrak [7].

En este escenario, los sensores EMG han demostrado ser una alternativa robusta y portable. El sistema NeuroPose, por ejemplo, utiliza señales EMG adquiridas desde el antebrazo para reconstruir en tiempo real la postura 3D de la mano mediante una arquitectura basada en redes neuronales recurrentes (RNN) y un esquema encoder-decoder. Este sistema alcanza un margen de error promedio de 6.24° en los ángulos articulares, siendo útil para el control de prótesis y la interacción con sistemas en tiempo real [5].

En la Figura 1.2 se ilustran los sensores utilizados en el sistema NeuroPose, los cuales se colocan en el antebrazo para captar la actividad muscular asociada al movimiento de los dedos. Cabe destacar que este brazalete no fue desarrollado por los autores de NeuroPose, sino que se basa en módulos comerciales de EMG, específicamente el Myo Armband, el cual cuenta con 8 sensores distribuidos de forma uniforme alrededor del antebrazo.



Figura 1.2: Sensores utilizados en el sistema NeuroPose [5].

Más recientemente, el sistema WETrak ha planteado la posibilidad de desplazar los sensores EMG desde el antebrazo proximal al distal, facilitando así su integración en dispositivos portátiles como relojes inteligentes o bandas de muñeca [8]. Aunque el antebrazo distal presenta un área con mayor superposición muscular y menor superficie para la colocación de sensores, WETrak enfrenta este desafío utilizando cinco sensores estratégicamente posicionados y una arquitectura de red neuronal con bloque de atención espacial. Este bloque permite al sistema enfocarse dinámicamente en las señales más relevantes para cada dedo, mejorando así la precisión del seguimiento. Además, la red está dividida en tres ramas especializadas, cada una dedicada a un grupo de dedos (pulgar; índice, medio y anular; meñique), lo que permite una representación más ajustada de la actividad muscular. WETrak logra reducir el error de predicción a un rango entre 4.94° y 7.68° , superando a NeuroPose en precisión y portabilidad.

En la Figura 1.3 se ilustran los sensores utilizados en el sistema WETrak, los cuales se colocan en la región distal del antebrazo para captar la actividad muscular asociada al movimiento de los dedos. A diferencia del Myo Armband, que integra ocho sensores EMG en un solo dispositivo portátil e inalámbrico,

WETrak utiliza cinco sensores EMG comerciales independientes, ubicados manualmente sobre músculos clave. Estos sensores no están integrados en una pulsera ni poseen conectividad inalámbrica, por lo que se conectan mediante cables a un microcontrolador encargado de digitalizar y transmitir las señales a un computador.




Figura 1.3: Sensores utilizados en el sistema WETrak [8].

Ambos sistemas representan avances importantes en el seguimiento articular de la mano, sentando las bases para nuevas aplicaciones en control de dispositivos vestibles, rehabilitación y accesibilidad, especialmente en contextos donde los métodos visuales tradicionales son limitados por el entorno. Sin embargo, aún presentan ciertas limitaciones. Por ejemplo, NeuroPose depende de sensores comerciales integrados en un brazalete genérico, sin considerar variaciones en la colocación del dispositivo, mientras que WETrak, si bien mejora la precisión al emplear una arquitectura especializada, utiliza sensores independientes conectados por cables, sin integración en un formato portátil ni evaluación en sesiones múltiples.

En este trabajo se propone un sistema basado en redes neuronales profundas que estima los ángulos articulares de los dedos a partir de señales EMG adquiridas desde el antebrazo distal, buscando una solución más precisa, cómoda y adaptable a dispositivos vestibles. A diferencia de trabajos previos, el sistema desarrollado integra sensores, electrónica y visualización en una única pulsera inalámbrica, permitiendo registrar datos en sesiones con recolocación del dispositivo para mejorar su robustez frente a cambios de montaje. Esta propuesta apunta no solo a una arquitectura eficaz, sino también a una mayor usabilidad en escenarios reales.

1.2 Objetivos

1.2.1 Objetivo general

Desarrollar una pulsera basada en sensores EMG capaz de estimar en tiempo real los ángulos articulares de los dedos mediante redes neuronales, con el fin de ser utilizada en interfaces hombre-máquina basadas en señales biológicas.

1.2.2 Objetivos específicos

- Desarrollar una pulsera equipada con sensores EMG para la adquisición de datos musculares de la mano, capturando diferentes gestos y actividades que permitan construir un conjunto de datos representativo de la actividad muscular.
- Procesar las señales fisiológicas adquiridas y utilizar redes neuronales para predecir los ángulos articulares de los dedos de la mano.
- Desarrollar las herramientas necesarias para evaluar el rendimiento del sistema en tiempo real.
- Realizar pruebas de validación en diferentes usuarios para evaluar la efectividad y precisión de la pulsera EMG.

1.3 Alcance y limitaciones

- La pulsera considera 5 sensores para adquirir datos musculares.
- Se utilizará la biblioteca disponible MediaPipe de Google para la adquisición de los ángulos articulares de los dedos de la mano.
- Solo se utilizarán modelos basados en redes neuronales para la predicción de los ángulos articulares.
- Las señales EMG pueden contener ruido, lo que podría dificultar la predicción precisa de los movimientos finos de los dedos, especialmente en el caso de movimientos de baja amplitud.

- La calidad de los datos adquiridos depende de la colaboración de terceros, lo que implica un riesgo de que estos datos no sean consistentes o precisos, afectando la calidad de la base de datos y, en consecuencia, el entrenamiento y rendimiento del modelo.

1.4 Metodología

Se utilizarán cinco sensores EMG colocados en el antebrazo distal para adquirir señales musculares asociadas al movimiento de los dedos. Simultáneamente, se utilizará la biblioteca MediaPipe de Google para obtener los ángulos articulares de las falanges, los cuales servirán como etiquetas para el entrenamiento. Se adquirirá una base de datos con las señales EMG y sus respectivos ángulos articulares, registrada durante la ejecución de gestos predefinidos por parte de múltiples participantes. Todos los sujetos firmarán previamente un consentimiento informado, aprobado por el Comité de Ética de la Facultad de Ingeniería de la Universidad de Concepción.

Además, se desarrollará un modelo de redes neuronales convolucionales que permitirá predecir los ángulos articulares a partir de las señales adquiridas. El rendimiento del modelo se validará usando métricas de error y pruebas en distintos usuarios, incluyendo personas no vistas durante el entrenamiento, para evaluar su precisión y capacidad de generalización. Finalmente, se desarrollará una interfaz gráfica que permita visualizar en tiempo real tanto las señales EMG como los ángulos predichos.

1.5 Temario

- **Capítulo 1. Introducción:** Introducción de manera general indicando la metodología, objetivos y alcances del proyecto.
- **Capítulo 2. Marco Teórico:** En esta sección se presenta el marco teórico, proporcionando un contexto detallado sobre la EMG, electrónica, y las redes neuronales utilizadas. También se incluye una revisión del estado del arte, resumiendo las investigaciones más recientes y relevantes en este campo.
- **Capítulo 3. Diseño de la Pulsera:** Esta sección proporciona información detallada sobre los componentes electrónicos utilizados, el posicionamiento de los electrodos y la elaboración del circuito.
- **Capítulo 4. Construcción del Conjunto de Datos:** Esta sección explica el procedimiento para adquirir la base de datos.

- **Capítulo 5. Diseño del Modelo de Redes Neuronales:** En esta sección se presenta la estructura del modelo diseñado.
- **Capítulo 6. Resultados:** En esta sección se muestra los resultados de cada dedo, tanto en condiciones intrausuario como interusuario, evaluando la precisión del modelo y su capacidad de generalización.
- **Capítulo 7. Discusión y Conclusión:** En esta sección se analizan los resultados finales.

Capítulo 2. Marco Teórico

En este capítulo se abarcarán los conceptos teóricos necesarios para comprender el funcionamiento del sistema propuesto. Se explicarán los principios de la electromiografía, la anatomía del antebrazo y los dedos, así como los fundamentos de las redes neuronales utilizadas en el modelo de predicción.

2.1 Anatomía del Antebrazo


Para comprender cómo se generan las señales electromiográficas (EMG) y cuáles son los músculos relevantes en el análisis de los movimientos de los dedos, es fundamental conocer la anatomía del antebrazo, abarcando tanto los músculos superficiales como los profundos, ya que ambos contribuyen a los movimientos de flexión y abducción de los dedos. Los músculos del antebrazo se dividen en dos compartimentos principales: anterior y posterior, cada uno con músculos específicos que desempeñan funciones clave.

2.1.1 Músculos Posteriores


Los músculos del compartimento posterior del antebrazo se encargan de la extensión de los dedos y de la extensión de la muñeca [9]. En este compartimento se encuentran tanto músculos superficiales como profundos que juegan un papel importante en el movimiento de los dedos:

- **Extensor carpi radialis longus y extensor carpi radialis brevis (superficiales):** Estos músculos extienden y abducen la muñeca, y son importantes en la estabilización durante los movimientos de los dedos [9].
- **Extensor digitorum (superficial):** Extiende los cuatro dedos principales y es clave en la extensión y separación de los dedos [9].
- **Extensor carpi ulnaris (superficial):** Contribuye a la extensión y aducción de la muñeca [9].
- **Extensor pollicis longus y extensor pollicis brevis (profundos):** Son responsables de la extensión del pulgar, un movimiento esencial para la manipulación de objetos [9].

- **Abductor pollicis longus (profundo):** Abduce el pulgar, permitiendo la apertura de la mano y facilitando los movimientos de agarre [9].
- **Extensor indicis (profundo):** Se encarga de la extensión del dedo índice, permitiendo movimientos independientes y precisos. Este converge con el músculo extensor pollicis longus al nivel de la muñeca [9].



(a) Músculos Superficiales Posteriores



(b) Músculos Profundos Posteriores

Figura 2.1: Músculos superficiales y profundos del compartimento posterior del antebrazo [10].


Los músculos que más destacan son el extensor digitorum, extensor pollicis longus y brevis, y abductor pollicis longus, puesto que son los principales responsables de los movimientos de los dedos.

2.1.2 Músculos Anteriores


Los músculos del compartimento anterior se encargan principalmente de la flexión de los dedos y de la flexión y pronación de la muñeca [9]. En este compartimento se encuentran tanto músculos superficiales como profundos que son importantes para las funciones motoras de la mano:

- **Pronator teres (superficial):** Facilita la pronación del antebrazo, colaborando en movimientos complejos de la mano y muñeca [9].

- **Flexor carpi radialis y palmaris longus (superficiales):** Estos músculos flexionan la muñeca y son importantes en la preparación de la mano para realizar movimientos de agarre [9].
- **Flexor carpi ulnaris (superficial):** Flexiona y aduce la muñeca, contribuyendo a la estabilidad de la mano durante la flexión de los dedos [9].
- **Flexor digitorum superficialis (intermedio):** Este músculo flexiona las falanges proximales de los dedos (índice, medio, anular y meñique) y juega un papel clave en la captura de señales EMG para la flexión inicial de los dedos [9].
- **Flexor digitorum profundus (profundo):** Flexiona las falanges distales de los dedos, siendo esencial para cerrar completamente la mano y ejecutar movimientos finos y precisos [9].
- **Flexor pollicis longus (profundo):** Flexiona el pulgar y es crucial en la realización de agarres y tareas de manipulación [9].
- **Pronator quadratus (profundo):** Ayuda en la pronación del antebrazo, colaborando con el pronator teres para movimientos de rotación [9].



(a) Músculos Superficiales Anteriores



(b) Músculos Profundos Anteriores

Figura 2.2: Músculos superficiales y profundos del compartimento anterior del antebrazo [11].

Los músculos que más destacan son el flexor digitorum superficialis, flexor digitorum profundus, y flexor pollicis longus, ya que son los principales responsables de la flexión de los dedos.

2.2 Movimientos de los Dedos

Los movimientos de los dedos se describen comúnmente en términos de dos ángulos principales: pitch y yaw, los cuales se refieren a los movimientos de las falanges en relación con sus articulaciones [12].

2.2.1 Pitch (Flexión y Extensión)

El pitch se refiere al movimiento de flexión y extensión de las falanges. Este movimiento ocurre en un plano sagital, permitiendo que el dedo se doble hacia la palma (flexión) o se extienda lejos de ella (extensión) [12]. Cada dedo tiene tres articulaciones principales que controlan este ángulo:

- **Articulación Metacarpofalángica (MCP):** Permite la flexión y extensión del dedo en la base de la falange proximal [12].
- **Articulación Interfalángica Proximal (PIP):** Controla la flexión y extensión de la falange intermedia en relación con la falange proximal [12].
- **Articulación Interfalángica Distal (DIP):** Permite la flexión y extensión de la falange distal [12].

El ángulo de pitch en estas articulaciones varía para permitir el cierre completo de la mano (agarrar un objeto) o la apertura de la misma, siendo importante en tareas como la manipulación y el agarre.

2.2.2 Yaw (Abducción y Aducción)

El yaw se refiere al movimiento lateral del dedo, es decir, la abducción (alejamiento del dedo de la línea media de la mano) y la aducción (movimiento hacia la línea media). Este movimiento es más evidente en la articulación MCP, donde los dedos se pueden separar unos de otros o acercarse [12].

Es importante notar que este ángulo es menos prominente en las articulaciones PIP y DIP, las cuales se enfocan más en la flexión y extensión (pitch) [12].




Figura 2.3: La rotación de la mano incluye tres orientaciones diferentes: roll, pitch y yaw [13].




Figura 2.4: Huesos que contiene una mano humana, incluyendo las articulaciones MCP, PIP y DIP [14].

2.3 Electromiografía

La EMG es una técnica utilizada para medir y registrar la actividad eléctrica producida por los músculos esqueléticos. Las señales EMG se generan cuando los músculos se contraen, ya que al hacerlo, las neuronas motoras envían impulsos eléctricos que causan esta contracción. Estas señales eléctricas pueden ser captadas mediante electrodos colocados en la superficie de la piel o insertados directamente en el músculo [5].

La EMG es especialmente útil para estudiar la fisiología muscular, la fatiga, la activación muscular y su control neurológico. En aplicaciones biomédicas, el análisis de las señales EMG ha permitido avances en áreas como la rehabilitación, el control de prótesis y las interfaces cerebro-máquina [15]. El potencial

de acción muscular, que es la base de la señal EMG, se genera cuando las motoneuronas transmiten impulsos eléctricos hacia las fibras musculares. Este impulso produce una pequeña corriente eléctrica que puede medirse. Las señales EMG se caracterizan por su baja amplitud (en el rango de los microvoltios) y por su naturaleza oscilante y ruidosa, lo que requiere un procesamiento y amplificación para su análisis adecuado [15].

2.3.1 Tipos de EMG

Existen dos tipos principales de EMG: superficial e intramuscular. La Electromiografía Superficial (sEMG) utiliza electrodos colocados en la superficie de la piel sobre el músculo que se desea medir. Este método es no invasivo, lo que lo hace más cómodo al momento de usar. Sin embargo, un desafío es que puede captar señales de varios músculos cercanos al mismo tiempo, lo que complica el análisis específico de músculos individuales [15]. Por otro lado, la EMG intramuscular utiliza electrodos en forma de aguja que se insertan directamente en el músculo que se desea medir. Aunque este método es invasivo, proporciona datos más precisos y específicos sobre la actividad del músculo en cuestión, ya que las señales captadas provienen exclusivamente de ese músculo [15].

En esta memoria se optará por utilizar sEMG para la fabricación de la pulsera, debido a que es no invasivo, proporcionando mayor comodidad para el usuario y facilidad de implementación, lo que lo hace más adecuado para el uso cotidiano y prolongado.

2.3.2 Procesamiento de Señales

El procesamiento de señales EMG es fundamental para la extracción de información importante sobre la actividad muscular.

La información fisiológicamente significativa de las señales EMG se encuentra típicamente entre 50 y 150 Hercios (Hz), ya que en ese rango se concentra la mayor parte de la energía útil asociada a la activación muscular. Este intervalo puede variar dependiendo del tipo de músculo y del nivel de contracción, pero en general, las componentes más relevantes para el análisis se sitúan dentro de ese rango [16].

Por otro lado, la amplitud de las señales EMG de superficie puede variar entre 0.1 mV y 5 mV, dependiendo de factores como el músculo analizado, la intensidad de la contracción y la correcta colocación de los electrodos. Este bajo nivel de voltaje requiere amplificación para mejorar la relación señal/ruido y

facilitar su posterior análisis [4].

Además, existen características temporales y espectrales comúnmente extraídas para análisis o clasificación, como el valor medio absoluto (MAV), la raíz cuadrática media (RMS), la frecuencia media (MNF), la frecuencia mediana (MDF), la varianza o el número de cruces por cero (ZC), todas las cuales reflejan aspectos relevantes del reclutamiento muscular, la fatiga y la modulación de fuerza [4].

2.3.3 Filtros

Los filtros son dispositivos o circuitos electrónicos que permiten el paso de señales dentro de un rango de frecuencias específico mientras atenúan o eliminan aquellas fuera de ese rango. Son fundamentales en el procesamiento de señales, ya que mejoran la calidad de las señales capturadas, reducen el ruido no deseado y extraen información relevante [17]. Existen varios tipos de filtros.

- **Filtros pasa bajos:** Permiten el paso de señales con frecuencias inferiores a una frecuencia de corte determinada y atenúan las superiores [17].
- **Filtros pasa altos:** Permiten el paso de frecuencias superiores a un valor de corte y atenúan las frecuencias por debajo de este [17].
- **Filtros pasa banda:** Permiten el paso de un rango específico de frecuencias, mientras atenúan las señales fuera de ese rango, tanto por encima como por debajo [17].
- **Filtros rechaza banda o notch:** Atenúan un rango específico de frecuencias mientras permiten el paso de señales fuera de este. Este tipo de filtro es comúnmente utilizado para eliminar interferencias en frecuencias específicas, como el ruido de la red eléctrica a 50/60 Hz [17].

2.4 Componentes Electrónicos

2.4.1 Microcontrolador

Un Microcontrolador (MCU) es un circuito pequeño integrado que contiene un procesador, memoria y periféricos de entrada/salida. Su principal función es ejecutar instrucciones de un programa para controlar dispositivos electrónicos. Los MCU se utilizan comúnmente en sistemas embebidos debido a su bajo costo, tamaño compacto y bajo consumo de energía [18].

2.4.2 Convertidor Análogo Digital

Un Convertidor Análogo Digital (ADC) es un dispositivo que transforma señales analógicas, que son continuas tanto en tiempo como en amplitud, en señales digitales, que son discretas en ambos aspectos. Las señales analógicas, como las variaciones de voltaje generadas por una señal EMG, representan información del mundo real en forma continua. Para que un sistema digital, como un MCU, pueda procesar estas señales, es necesario convertirlas a formato digital [19].

Dos características clave de un ADC son la resolución y la tasa de muestreo. La resolución se refiere al número de bits utilizados por el convertidor para representar la señal analógica en formato digital. Un ADC con una resolución de 10 bits puede representar la señal en uno de 1,024 (2^{10}) niveles diferentes. Cuanto mayor sea la resolución, mayor es la capacidad del sistema para captar pequeñas variaciones en la señal de entrada, lo cual es muy importante para señales como las EMG, que tienen variaciones muy sutiles en su amplitud [19].

Por otro lado, la tasa de muestreo es la cantidad de muestras que el ADC toma por segundo y se mide en Muestras por Segundo (SPS) o en Hz. La tasa de muestreo determina la frecuencia máxima que el sistema puede capturar sin perder información, evitando el efecto de aliasing. Según el teorema de Nyquist, la tasa de muestreo debe ser al menos el doble de la frecuencia más alta presente en la señal [19]. En el caso de las señales EMG, cuya frecuencia principal está en el rango de 100 a 150 Hz, una tasa de muestreo de 500 SPS es adecuada para captar con precisión las señales musculares.

2.4.3 Amplificador

Un amplificador es un dispositivo electrónico diseñado para aumentar la amplitud de una señal eléctrica, ya sea de voltaje, corriente o potencia, sin modificar su forma original. Su función es esencial en una amplia gama de aplicaciones, desde sistemas de audio hasta equipos médicos, como en la EMG. El amplificador toma una señal de entrada de baja amplitud y, utilizando una fuente de energía externa, la amplifica para producir una señal de salida proporcionalmente más fuerte.

Existen varios tipos de amplificadores, cada uno diseñado para cumplir funciones específicas según las necesidades de la aplicación, unos ejemplos son:

- **Amplificador Operacional:** Pueden amplificar voltaje, realizar sumas o restas de señales, generar comparaciones de voltaje, o actuar como filtros [17].

- **Amplificador Inversor:** El amplificador inversor es un componente que invierte el voltaje de una señal de entrada. Se utiliza cuando se necesita un voltaje negativo para el funcionamiento de otros circuitos en un sistema que solo dispone de fuentes de alimentación positiva [17].
- **Amplificador de Instrumentación:** Este tipo de amplificador se utiliza para amplificar señales pequeñas y de baja amplitud con alta precisión y estabilidad [19], siendo ideal para aplicaciones en sensores y en mediciones biológicas, como las señales EMG.

2.5 Redes Neuronales Artificiales

Las Redes Neuronales Artificiales (ANN) son un tipo de modelo computacional inspirado en el cerebro humano, diseñadas para reconocer patrones complejos en datos. Están compuestas por capas de nodos o "neuronas", cada una de las cuales recibe y procesa entradas para producir una salida. Este proceso se utiliza en diversas aplicaciones, como clasificación, regresión y predicción, debido a su capacidad para aprender automáticamente de grandes volúmenes de datos [20].

El procesamiento de señales EMG es un desafío debido a la naturaleza ruidosa y variable de las señales musculares. Las redes neuronales, en especial las redes neuronales profundas, han demostrado ser eficaces para extraer características relevantes de estas señales y modelar los movimientos de los dedos de manera precisa [20]. Su capacidad para identificar patrones complejos y no lineales en grandes volúmenes de datos las convierte en una herramienta ideal para este tipo de problemas.

2.5.1 Redes Neuronales Convolucionales Redes Neuronales Convolucionales (CNN)

Las CNN son un tipo de red neuronal diseñada específicamente para procesar datos con estructura espacial o temporal, como imágenes o secuencias de señales. La convolución es un proceso matemático que permite a las CNN identificar patrones locales en los datos de entrada, como las características espaciales en imágenes o las correlaciones temporales en señales EMG [21].

En este proyecto, las CNN se utilizan para extraer patrones espaciales y temporales de las señales EMG. Estas señales, que reflejan la actividad eléctrica de los músculos durante los movimientos de los dedos, contienen información relevante que las CNN son capaces de procesar eficientemente. Al capturar las correlaciones entre las señales y los movimientos, las CNN permiten modelar con precisión los ángulos de las articulaciones [22].

2.5.2 Mecanismo de Atención

Los mecanismos de atención son una técnica que permite a los modelos enfocarse en las características más relevantes de los datos, asignando pesos diferentes a distintas partes de la entrada. Esto es especialmente útil en el procesamiento de grandes cantidades de datos, donde no toda la información es igualmente importante [23]. En el caso de las señales EMG, los mecanismos de atención permiten que el modelo identifique qué partes de la señal contienen la información más importante para predecir los movimientos de los dedos. Al asignar un mayor peso a las características más relevantes, se mejora significativamente la precisión del modelo, ya que se minimiza el impacto de las partes menos informativas de la señal [22].

Una variante especializada es la atención por canal, la cual recalibra dinámicamente la importancia de cada canal de entrada en función de su relevancia contextual. Este tipo de atención es particularmente útil en señales EMG, donde no todos los sensores aportan la misma cantidad de información para cada movimiento. Al asignar pesos diferenciados a cada canal, el modelo puede amplificar las señales musculares más significativas y suprimir aquellas menos relevantes o ruidosas, lo que mejora la precisión de la estimación articular [24, 25].

2.5.3 Redes Neuronales Residuales Redes Neuronales Residuales (ResNet)

Las ResNet, fueron introducidas por He et al. en 2016 con el objetivo de facilitar el entrenamiento de redes neuronales profundas sin que su rendimiento se degrade a medida que aumentan las capas [26]. Su principal innovación consiste en el uso de conexiones de atajo (skip connections) que permiten que las capas aprendan correcciones (residuos) sobre la identidad en lugar de tener que aprender la transformación completa de los datos.

Esto significa que cada bloque residual no necesita transformar completamente su entrada, sino que puede centrarse en refinarla, lo que simplifica la optimización del modelo. Estas conexiones ayudan a evitar el desvanecimiento del gradiente durante el entrenamiento y permiten construir modelos más profundos y precisos.

En el contexto del procesamiento de señales EMG, las redes residuales han demostrado ser eficaces para manejar datos ruidosos y complejos, como los que provienen de la contracción muscular. Su capacidad para mantener el flujo de información a través de la red y aprender representaciones jerárquicas contribuye a una mayor estabilidad durante el entrenamiento y una mejor generalización del modelo

[22, 27].

En este proyecto, se incorporan bloques residuales en la arquitectura del modelo para reforzar la robustez del sistema y mejorar la capacidad de aprender patrones musculares sutiles, sin incrementar innecesariamente la complejidad computacional.

2.6 Discusión

A lo largo de este capítulo se ha revisado el estado del arte y los fundamentos anatómicos, tecnológicos y computacionales que sustentan el desarrollo de sistemas de seguimiento de movimiento de dedos mediante EMG. Esta exploración permite contextualizar las decisiones de diseño adoptadas en este proyecto y valorar sus implicancias frente a otras soluciones disponibles.

En primer lugar, se observa que las tecnologías basadas en visión (como cámaras RGB, de profundidad o térmicas) han demostrado un desempeño notable en condiciones controladas, pero presentan limitaciones importantes en escenarios reales. La necesidad de mantener línea de vista, la dependencia de la iluminación, y la sensibilidad al entorno restringen su uso en condiciones cotidianas o en dispositivos portátiles [8, 6, 7]. Frente a ello, los sensores EMG ofrecen una alternativa robusta y versátil, capaces de captar la intención de movimiento directamente desde la actividad muscular, sin necesidad de contacto visual ni calibraciones ambientales.

Dentro de las soluciones EMG, sistemas como NeuroPose y WETrak han establecido un marco de referencia. NeuroPose demostró la viabilidad de predecir poses tridimensionales de la mano desde el antebrazo proximal usando Redes Neuronales Recurrentes (RNN), mientras que WETrak fue más allá al posicionar sensores cercano a la muñeca, lo que facilita la integración en wearables y mejora la usabilidad, aunque plantea desafíos adicionales debido a la complejidad anatómica de esta zona [8, 5].

Este proyecto se alinea con esa última línea de trabajo, optando por el uso de señales EMG captadas en el antebrazo distal. La revisión anatómica muestra que tanto músculos extensores como flexores asociados a los dedos pueden generar señales distinguibles desde esta ubicación, aunque con solapamiento, lo que justifica la necesidad de técnicas de procesamiento más avanzadas. Por ello, se recurre al uso de CNN, mecanismos de atención y ResNet, capaces de extraer patrones relevantes en señales ruidosas y de alta variabilidad temporal [22, 23, 26].

Capítulo 3. Diseño de la Pulsera

Este capítulo describe el sistema de adquisición de señales electromiográficas (EMG) utilizado en este proyecto. Se optó por utilizar módulos EMG comerciales integrados, los cuales incluyen todos los componentes necesarios para captar, amplificar, filtrar y entregar una señal lista para ser procesada digitalmente. A continuación, se detallan sus características internas, la plataforma de adquisición utilizada y la estrategia de posicionamiento para maximizar la calidad de las señales obtenidas.

3.1 Módulo EMG

Cada módulo EMG cuenta con tres electrodos metálicos integrados directamente en la parte inferior de la placa. Están fabricados en cobre chapado en oro, lo que mejora la conductividad eléctrica. Este tipo de electrodo seco permite una colocación directa sin necesidad de geles conductores, lo que facilita su uso en aplicaciones portátiles y repetitivas [28].

El sensor contiene un amplificador de instrumentación, presumiblemente el modelo INA333 (Texas Instruments), encargado de amplificar la señal eléctrica diferencial generada por la contracción muscular. Este tipo de amplificador ofrece una ganancia alta y configurable, una impedancia de entrada elevada, y un buen rechazo al ruido común, lo que lo hace ideal para captar señales EMG de muy baja amplitud (entre 50 y 500 μV) sin distorsión [29].

Después de la amplificación, la señal pasa por una etapa de filtrado analógico compuesta por un segundo amplificador operacional (modelo LMV358). Este componente permite construir un filtro pasa banda que atenúa frecuencias no deseadas. El módulo implementa un filtrado dentro del rango de 20 a 150 Hz, lo cual es coherente con el espectro de frecuencias más informativo en señales EMG, ya que elimina tanto artefactos de movimiento (baja frecuencia) como interferencias electromagnéticas (alta frecuencia) [4, 30].

Los amplificadores operacionales requieren una alimentación simétrica para funcionar correctamente. Como el sistema solo dispone de una fuente positiva (desde una batería), el módulo incluye un circuito inversor de voltaje, basado en el componente TPS60403. Este convertidor genera una tensión negativa (aproximadamente 3 V) a partir de la fuente positiva, utilizando capacitores conmutados. Esto permite que los amplificadores funcionen dentro de su rango operativo, sin necesidad de una fuente de alimenta-

ción externa adicional [31].

Para asegurar una tensión estable en los componentes internos, el módulo incorpora un regulador de voltaje de baja caída (LDO), que convierte la alimentación de entrada (3.7 a 5 V) en una línea interna de 3.3 V. Este regulador mantiene la estabilidad del circuito incluso en presencia de pequeñas variaciones de la fuente principal, lo cual es crucial para evitar fluctuaciones en la ganancia o distorsión del filtrado.

La señal final se entrega mediante un pin de salida analógica. Esta salida se conecta directamente a un microcontrolador para su digitalización. Junto con esta línea, se disponen los pines de alimentación (entrada de voltaje positivo y tierra), lo que permite una integración sencilla mediante conectores de tres pines.

3.2 Plataforma de adquisición y transmisión

3.2.1 Microcontrolador ESP32-S3 SuperMini

El microcontrolador utilizado en este sistema es el ESP32-S3 SuperMini, una placa compacta y de bajo consumo que incorpora un procesador de 32 bits con doble núcleo a 240 MHz. Este módulo ofrece múltiples entradas analógicas (ADC) con resolución de hasta 12 bits y cuenta con conectividad inalámbrica por Bluetooth Low Energy (BLE) 5.0.

El sistema fue configurado para leer simultáneamente las señales de cinco sensores EMG a una frecuencia de muestreo de 500 Hz por canal. Esta tasa es suficiente para captar el contenido espectral útil de las señales EMG, y cumple con el teorema de Nyquist para señales cuya frecuencia máxima se sitúa en torno a 150 Hz [32].

3.2.2 Transmisión inalámbrica

Una vez digitalizadas, las señales EMG son transmitidas mediante Bluetooth Low Energy a un computador. BLE fue elegido debido a su bajo consumo energético y su capacidad de mantener conexiones estables y de baja latencia, características especialmente importantes en aplicaciones portátiles. La transmisión inalámbrica también mejora la ergonomía del sistema y elimina la necesidad de cables de datos durante su uso.

3.3 Posicionamiento de los sensores

Los cinco sensores EMG se distribuyen en torno a la muñeca del usuario, orientados a captar la actividad de los principales músculos involucrados en el control de los dedos. La Figura 3.1 ilustra la ubicación aproximada de los sensores, alineados con los siguientes grupos musculares:

- Flexor digitorum superficialis
- Flexor digitorum profundus
- Flexor pollicis longus
- Extensor digitorum
- Extensor pollicis longus y brevis
- Abductor pollicis longus




Figura 3.1: Distribución de los sensores EMG sobre la muñeca, alineados con los principales músculos responsables del movimiento de los dedos [10, 11].

La elección de esta ubicación responde a la necesidad de construir un sistema compacto y usable como dispositivo vestible. Aunque la muñeca presenta mayor superposición muscular que el antebrazo,

estudios recientes han demostrado que es posible capturar señales EMG útiles desde esta zona para predecir con precisión los movimientos de los dedos [8]. Si bien esta configuración no garantiza la selectividad muscular ideal, la disposición estratégica de los sensores permite una cobertura funcional adecuada, manteniendo la portabilidad y simplicidad del sistema.

3.4 Energización del sistema

Para asegurar la portabilidad del dispositivo, se utiliza una batería recargable de polímero de litio (LiPo) de 3.7 V como fuente principal de alimentación. Este tipo de batería es liviano, compacto y posee una buena capacidad de almacenamiento energético, lo cual la hace ideal para aplicaciones vestibles.

La batería se conecta a un módulo cargador USB, que permite su recarga. Esta salida se conecta al pin de alimentación del ESP32-S3 SuperMini. El microcontrolador regula internamente una línea de 3.3 V, la cual es utilizada para alimentar directamente los cinco sensores EMG. Esta configuración asegura un suministro estable para todos los componentes desde una sola fuente recargable.

Esta arquitectura permite mantener una operación continua, simplificar el cableado interno, y facilita la recarga del sistema sin necesidad de desmontar la pulsera.

3.5 Diseño y Fabricación de la Carcasa de la Pulsera

La carcasa del sistema fue diseñada para alojar cinco módulos de sensores EMG, distribuidos equidistantemente en una estructura flexible que permite adaptarse a la forma de la muñeca. En la Figura 3.2 se muestra el diseño final con sus dimensiones principales.




Figura 3.2: Vista superior de la carcasa impresa para la pulsera con sensores EMG (medidas en milímetros).

El proceso de impresión 3D se realizó utilizando filamento TPE (elastómero termoplástico), un material flexible y cómodo para contacto prolongado con la piel. La fabricación tuvo una duración total de 4 horas, utilizando aproximadamente:

- **Peso de material:** 49,83 gramos.
- **Longitud de filamento consumido:** 16,7 metros.

El diseño incluye compartimientos individuales para cada sensor, con aberturas para facilitar el contacto de los electrodos con la piel. También se considera un espacio central para alojar el microcontrolador y la batería, permitiendo mantener una estructura compacta y ergonómica.

En las Figuras 3.3, 3.4 y 3.5 se muestran diferentes vistas del prototipo final de la pulsera, destacando su diseño ergonómico y la disposición de los componentes electrónicos.



Figura 3.3: Vista superior del prototipo final de la pulsera EMG colocada en el antebrazo distal del usuario.



Figura 3.4: Vista inferior del diseño impreso en 3D. Se observan los cinco sensores EMG adheridos mediante una correa, y el cableado interno entre los módulos.




Figura 3.5: Detalle del compartimento interno que contiene la electrónica de adquisición, alimentación y transmisión.

Capítulo 4. Construcción del Conjunto de Datos

Este capítulo describe el sistema desarrollado para la captura sincronizada de señales EMG y los ángulos articulares de los dedos, utilizando una interfaz gráfica personalizada con soporte para conexión Bluetooth Low Energy (BLE) y seguimiento de manos con MediaPipe.

4.1 Captura de Ángulos con MediaPipe

Para obtener las etiquetas necesarias para entrenar el modelo a partir de señales EMG, se utiliza el modelo *Hands* de la biblioteca MediaPipe, desarrollada por Google. Este modelo es capaz de detectar 21 puntos tridimensionales en la mano utilizando imágenes RGB, sin necesidad de marcadores ni sensores adicionales. Los puntos detectados corresponden a las articulaciones de los dedos y la palma, lo que permite reconstruir la postura de la mano en tres dimensiones.

A partir de estas coordenadas, se calcula el valor de los ángulos articulares en las articulaciones MCP, PIP y DIP de cada dedo, utilizando operaciones geométricas como productos vectoriales y proyecciones en planos específicos.

- **Pitch:** Se calcula para cada una de las tres falanges (proximal, media y distal) utilizando tres puntos consecutivos A , B y C a través del producto escalar:

$$\theta_{\text{pitch}} = \arccos \left(\frac{(B - A) \cdot (C - B)}{\|B - A\| \cdot \|C - B\|} \right)$$

En el caso del pulgar, se ajusta el signo del ángulo en función del producto cruzado proyectado sobre el plano XY para mantener la coherencia del movimiento.

- **Yaw:** Se obtiene entre dos vectores proyectados sobre el plano XY (o YZ para el pulgar), originados desde la base de la palma hacia puntos clave del dedo:

$$\theta_{\text{yaw}} = \arccos \left(\frac{\vec{v}_1 \cdot \vec{v}_2}{\|\vec{v}_1\| \cdot \|\vec{v}_2\|} \right)$$

Según el dedo, se invierte el signo para reflejar la dirección del movimiento.

Cada dedo genera cuatro ángulos (tres de pitch y uno de yaw), sumando un total de 20 ángulos por fotograma.

4.1.1 Suavizado Temporal

Para evitar oscilaciones rápidas e irreales entre frames consecutivos —producto de pequeñas variaciones en la estimación de puntos— se aplica un filtro exponencial suavizado sobre los ángulos calculados:

$$\theta_t = \alpha \cdot \theta_t^{\text{actual}} + (1 - \alpha) \cdot \theta_{t-1}^{\text{previo}}$$

donde $\alpha \in (0, 1)$ representa el grado de suavizado. Este proceso mejora la coherencia temporal de las etiquetas y permite una representación continua del movimiento de la mano, sin sobresaltos artificiales.

4.1.2 Almacenamiento de los Datos

Los ángulos filtrados se almacenan en archivos JSON junto con su marca temporal. Para cada ventana de señal EMG (2 segundos), se generan cinco fotogramas de ángulos. Esto permite al modelo aprender no solo una postura instantánea, sino su evolución a lo largo del tiempo. En tiempo real, se utiliza únicamente el último fotograma como predicción final para representar el estado actual de la mano.

4.2 Interfaz de Usuario y Sincronización

La interfaz, desarrollada en PyQt5, permite al usuario ingresar su ID, seleccionar la sesión y definir la duración del registro. Además, se encarga de establecer la conexión con la pulsera mediante comunicación BLE. El visualizador integrado muestra en tiempo real las cinco señales EMG, junto con la reconstrucción tridimensional de los dedos basada en los ángulos estimados por MediaPipe. Esta visualización ayuda a validar la calidad de las señales y la precisión del seguimiento durante la captura.

Al iniciar la captura, se graban simultáneamente los datos EMG (en formato CSV) y los ángulos articulares (en formato JSON), mostrando en pantalla los segundos transcurridos. Ambos se almacenan en una carpeta estructurada por usuario y gesto. La sincronización entre ambas fuentes se logra mediante el uso de timestamps y una tasa de captura fija, garantizando alineación temporal precisa entre la actividad muscular y el movimiento de los dedos.




Figura 4.1: Interfaz gráfica durante la captura de datos. A la izquierda se visualizan las señales EMG en tiempo real, y a la derecha se muestra la reconstrucción 3D de los dedos, generada a partir de los ángulos articulares estimados con MediaPipe.

4.3 Formato y Estructura de los Datos

Cada sesión de captura genera dos archivos principales:

- **emg.csv:** contiene las muestras EMG con timestamps. Cada fila corresponde a una muestra y contiene cinco valores de voltaje.
- **angles.json:** contiene una lista de objetos, donde cada uno incluye un timestamp y un diccionario con los ángulos Pitch y Yaw para cada dedo. Cada dedo contiene tres valores de Pitch y uno de Yaw, calculados a partir de las coordenadas 3D extraídas por MediaPipe.

La organización jerárquica de carpetas permite registrar múltiples gestos por usuario, facilitando el entrenamiento supervisado del modelo posterior.

4.4 Gestos Realizados

Con el objetivo de capturar el rango completo de ángulos articulares de los dedos, se definió un conjunto de 25 gestos que abarcan diversas combinaciones de movimiento en los cinco dedos de la mano. Estos gestos fueron seleccionados para recorrer el espacio de flexión (Pitch) y rotación lateral (Yaw) de cada articulación. La Figura 4.2 presenta una ilustración esquemática de cada uno de ellos.




Figura 4.2: Representación esquemática de los 25 gestos utilizados durante la adquisición de datos.

Durante cada sesión de adquisición, el sujeto realiza los 25 gestos de forma secuencial. Para cada gesto, la mano parte desde una posición de reposo, ejecuta el gesto correspondiente, vuelve a la posición de reposo y luego procede al siguiente gesto, repitiendo este ciclo continuamente durante tres minutos. Esto permite capturar tanto la ejecución del gesto como las transiciones naturales entre gestos y reposo.

Las sesiones se organizan por pares. En la primera sesión de cada par, se ejecutan los 25 gestos en su forma original. En la segunda, se repiten los mismos gestos pero alternando la flexión del pulgar, con el objetivo de incorporar mayor variabilidad anatómica.

Cada par de sesiones se repite con una nueva colocación de la pulsera, sumando un total de 10 sesiones (5 colocaciones distintas). Aunque cada nueva colocación implica una leve rotación o desplazamiento del dispositivo sobre la muñeca, se garantiza que cada sensor permanezca alineado con su músculo objetivo.

La razón de esta recolocación es evitar que el modelo aprenda a predecir solo en una configuración fija, ya que pequeños desplazamientos en la posición del sensor modifican la señal muscular adquirida.

Al incluir estas variaciones durante el entrenamiento, se busca que el modelo sea más robusto frente a cambios en la colocación del dispositivo, mejorando su capacidad de generalización en condiciones reales de uso.

Esta metodología permite construir una base de datos rica en variabilidad tanto gestual como electromiográfica, la cual será utilizada para entrenar y evaluar el modelo de predicción. Los gestos utilizados fueron inspirados en la base de datos WETrak [8], pero fueron adaptados y extendidos para este estudio, con el fin de mantener la comparabilidad con trabajos previos y ampliar el rango de movimientos considerados.

4.5 Discusión

El sistema de adquisición desarrollado permitió registrar de forma sincronizada señales EMG y ángulos articulares de los dedos. La integración de una interfaz gráfica con soporte BLE facilitó la interacción con el sistema, mientras que la visualización en tiempo real de las señales y de la reconstrucción 3D permitió validar la calidad de los datos durante la captura.

El uso de MediaPipe como herramienta de seguimiento permitió estimar los ángulos articulares a partir de las coordenadas tridimensionales de los puntos de la mano, sin requerir hardware adicional. Sin embargo, fue necesario aplicar un filtrado temporal para reducir las oscilaciones propias del modelo y mejorar la calidad de los datos.

Por otra parte, el conjunto de 25 gestos definidos abarca una amplia variedad de configuraciones de la mano, permitiendo cubrir un espectro representativo de combinaciones articulares posibles. Esta diversidad es clave para entrenar modelos de regresión o clasificación con buena capacidad de generalización, especialmente en aplicaciones orientadas a la reconstrucción de movimientos de la mano.

Capítulo 5. Diseño del Modelo de Redes Neuronales

En este capítulo se describe la arquitectura del sistema diseñado para estimar los ángulos articulares de los dedos a partir de señales EMG adquiridas desde la muñeca. El sistema se ha diseñado para predecir los movimientos articulares de los cinco dedos, representados como secuencias de 20 DoFs (grados de libertad) correspondientes a las articulaciones MCP, PIP y DIP.

5.1 Preprocesamiento de Datos

5.1.1 Filtrado y Normalización

Las señales EMG se filtran con un pasa banda entre 20 y 150Hz, y se aplica un filtro notch a 50Hz para eliminar el ruido de la red eléctrica. Luego, cada ventana se normaliza canal por canal usando z-score (restar la media y dividir por la desviación estándar) para asegurar que todas las señales tengan una escala comparable y estable.

5.1.2 Interpolación y Suavizado de Ángulos

Como las señales EMG y los ángulos tienen frecuencias distintas, los ángulos se interpolan para que coincidan con la frecuencia EMG (500 Hz). Luego, se suavizan en tres etapas: un filtro de mediana para eliminar picos atípicos, un filtro de Savitzky-Golay para mantener la forma del movimiento, y se limita el valor de cada ángulo a un rango mínimo y máximo realista basado en la anatomía humana.

5.1.3 Segmentación en Ventanas y Etiquetado Secuencial

Las señales se dividen en ventanas de 500 muestras (1 segundo). Para cada ventana, no se predice un solo valor, sino una secuencia de 5 valores intermedios que representan la evolución del movimiento durante la ventana. Esto permite al modelo entender no solo en qué posición está la articulación, sino hacia dónde se dirige. Estos valores se extraen dividiendo la ventana de ángulos en cinco partes iguales.

5.1.4 Normalización de Ángulos

Los ángulos se normalizan utilizando los valores mínimos y máximos de cada ángulo, medidos a partir de todo el conjunto de datos. Esto asegura que el modelo trabaje con valores en el mismo rango [0, 1] sin perder información relativa entre gestos o sesiones diferentes.

5.1.5 Aumentación de Datos

Para mejorar la generalización del modelo, durante el entrenamiento se aplican transformaciones aleatorias como escalado, desplazamiento, adición de ruido blanco y pequeños desfasajes temporales (jitter). Estas transformaciones ayudan a que el modelo aprenda a generalizar mejor frente a nuevas posiciones o condiciones no vistas durante el entrenamiento.

5.2 Arquitectura del Modelo

La arquitectura propuesta tiene como objetivo traducir la actividad eléctrica capturada por sensores EMG en ángulos. El modelo se compone de tres módulos principales: un extractor de características (encoder), un bloque de atención que asigna relevancia a los distintos sensores según el dedo, y un decodificador especializado por dedo que genera los ángulos correspondientes. A continuación, se describe el propósito de cada componente.

5.2.1 Encoder

El encoder se encarga de procesar las señales EMG y extraer patrones significativos a través del tiempo. Está compuesto por varias capas convolucionales seguidas de normalización y funciones de activación ReLU. Estas capas permiten detectar cambios en la señal relacionados con la contracción muscular y facilitan el aprendizaje de patrones. Se utilizan bloques residuales para evitar que el modelo olvide información importante y para mejorar la estabilidad del entrenamiento. También se incluyen operaciones de reducción de tamaño (pooling) para concentrar la información más relevante.

5.2.2 Mecanismo de Atención

No todos los sensores EMG son igual de importantes para todos los dedos. Por eso, este bloque asigna un peso a cada canal de entrada dependiendo del dedo que se está analizando. Se implementa como una capa de atención que aprende a resaltar los sensores más útiles. Esto ayuda a reducir el ruido y mejora la precisión del modelo, especialmente cuando varios dedos se mueven al mismo tiempo.

5.2.3 Decoder

Finalmente, la información procesada pasa a un conjunto de decodificadores, uno para cada dedo. Cada decodificador está diseñado para interpretar los patrones musculares específicos y transformarlos en los ángulos articulares que describen el movimiento. Estos módulos también utilizan capas convolucionales y activaciones ReLU, seguidas de capas lineales que entregan como salida los ángulos de pitch y yaw de cada articulación. Además, cada decodificador incluye un mecanismo que estima la confianza del modelo en su predicción, lo cual se utiliza para ajustar dinámicamente el resultado final.

Además el modelo estima cinco momentos diferentes dentro de una misma ventana de un segundo. Esto permite capturar la evolución del movimiento a lo largo del tiempo y mejora la continuidad en las predicciones. Para la inferencia en tiempo real, se utiliza solo el último frame predicho, que representa el instante más reciente del movimiento.

La Figura 5.1 resume visualmente la estructura general del modelo propuesto.




Figura 5.1: Esquema general de la arquitectura propuesta. Se muestra el flujo de procesamiento desde las señales EMG (entrada) hasta la salida final de 20 ángulos articulares, pasando por el encoder convolucional, el bloque de atención y los decodificadores por dedo.

5.3 Función de Pérdida

Dado que la arquitectura está estructurada en forma *multi-head* —con una decodificación independiente por dedo—, se definió una función de pérdida que evalúa cada dedo de forma separada en cada frame.

Cada dedo genera cuatro salidas por frame: tres ángulos de flexión/extensión (*pitch*) y uno de orientación lateral (*yaw*). Para cada uno de los cinco frames predichos, se calcula la pérdida de forma individual por dedo, utilizando dos componentes:

1. **Error absoluto medio (L1)**: compara los valores predichos con los reales para cada ángulo de forma independiente, y luego promedia entre los cuatro ángulos del dedo.
2. **Pérdida direccional (coseno)**: evalúa si el vector completo de 4 ángulos del dedo predicho apunta en la misma dirección que el vector real, penalizando diferencias en la orientación del gesto.

Ambas pérdidas se calculan para cada dedo d y cada frame t de la secuencia. La función de pérdida total utilizada durante el entrenamiento es:

$$\mathcal{L}_{\text{total}} = \frac{1}{5 \times 5} \sum_{t=1}^5 \sum_{d=1}^5 \left[\left\| \hat{\theta}_{d,t} - \theta_{d,t} \right\|_1 + \lambda_{\cos} \cdot \left(1 - \cos(\hat{\theta}_{d,t}, \theta_{d,t}) \right) \right]$$

Donde:

- $\hat{\theta}_{d,t}$ y $\theta_{d,t}$ representan el vector de 4 ángulos predichos y reales del dedo d en el frame t .
- $\| \cdot \|_1$ es la norma L1, que suma los errores absolutos de cada componente.
- $\cos(\cdot, \cdot)$ indica la similitud direccional entre los dos vectores.
- $\lambda_{\cos}$ es un hiperparámetro que controla el peso relativo de la pérdida direccional (en este caso, se usó $\lambda_{\cos} = 2.0$).

5.4 Procedimiento para el Entrenamiento del Modelo

El modelo fue entrenado utilizando el optimizador Adam con una tasa de aprendizaje fija de 10^{-3} . Se emplearon lotes de tamaño 16 tanto en el conjunto de entrenamiento como en el de validación. El

entrenamiento fue ejecutado sobre la GPU disponible.

Antes del entrenamiento final, se llevó a cabo una búsqueda de hiperparámetros con el fin de determinar la configuración óptima del modelo. Este proceso incluyó la exploración de diferentes profundidades de red, tamaños de lote, tasas de aprendizaje y valores de dropout, permitiendo seleccionar una arquitectura que optimizara el rendimiento sin tener sobreajuste.

El número máximo de épocas fue establecido en 2000, aunque se utilizó *early stopping* con una paciencia de 25 épocas. Es decir, si la pérdida de validación no mejoraba en 25 ciclos consecutivos, el entrenamiento se detenía automáticamente para prevenir sobreajuste. Esta estrategia permite al modelo entrenar por un largo tiempo si es necesario, pero sin riesgo de sobreentrenamiento si la convergencia se alcanza tempranamente.

En cada época, el modelo procesa completamente el conjunto de entrenamiento y luego se evalúa sobre el conjunto de validación. Al final de cada época, si la pérdida de validación actual es menor que la mejor observada, se guarda automáticamente una copia del modelo en disco para su posterior uso en inferencia.

Una vez entrenado, el modelo genera predicciones normalizadas que luego se desnormalizan utilizando los mínimos y máximos globales. Se calculan métricas como MAE, MSE y correlación por dedo, y se grafican las secuencias reales vs. las predichas para evaluar visualmente la precisión y fluidez del sistema.

Capítulo 6. Resultados

Para evaluar el rendimiento del sistema en tiempo real, se desarrolló una interfaz gráfica que permite visualizar las predicciones del modelo junto con las etiquetas generadas por MediaPipe. La interfaz se conecta a la pulsera mediante comunicación BLE y adquiere en tiempo real las señales EMG, las cuales son procesadas por el modelo para entregar predicciones actualizadas cada 100ms. Además, ofrece opciones para seleccionar el modelo correspondiente a cada usuario, ajustar el tamaño de la ventana de entrada utilizada por la red neuronal, y aplicar suavizado a las predicciones cuando se requiera. El sistema fue evaluado inicialmente en condición intrausuario, utilizando datos de un sujeto presente en el conjunto de entrenamiento, y posteriormente en condición interusuario, con un sujeto no visto durante el entrenamiento.




Figura 6.1: Interfaz de predicción en tiempo real. La columna izquierda muestra la predicción del modelo, y la derecha corresponde al ground truth.

6.1 Evaluación Intrausuario

El modelo fue evaluado utilizando un conjunto de entrenamiento y validación provenientes del mismo sujeto. Esta configuración permite analizar el rendimiento del sistema en condiciones ideales, es decir, sin variabilidad intersujeto, y medir su capacidad para reconstruir con precisión los movimientos articulares a partir de señales EMG.

La Figura 6.2 presenta un conjunto de gestos correspondientes a letras de la lengua de señas chilena (LSCh). En cada bloque se muestra, a la izquierda, la predicción generada por el modelo y, a la derecha, el ground truth calculado a partir de las coordenadas 3D extraídas con MediaPipe.




Figura 6.2: Reconstrucción de letras de la lengua de señas chilena (LSCh) en condición intrausuario. La columna izquierda muestra la predicción del modelo, y la derecha corresponde al ground truth.

Las letras **I**, **L** y **A** presentan configuraciones articulares que son reproducidas por el modelo de forma visualmente similar al ground truth, manteniendo la forma general y la posición relativa de los dedos. Estas posturas no muestran desviaciones evidentes en la reconstrucción.

En contraste, algunas letras como **B** y **W** presentan discrepancias en articulaciones específicas: en **B** se observa una flexión adicional en el pulgar, y en **W**, una ligera flexión en el dedo anular que no está presente en la referencia. Aunque la silueta general del gesto se conserva, estas diferencias podrían afectar su reconocimiento en una tarea automatizada. Por otra parte, la letra **O** muestra una divergencia más significativa entre la predicción y el ground truth, ya que no se reproduce la forma circular esperada. Esto puede estar relacionado con la baja activación muscular requerida para ejecutar dicho gesto, lo que limita la información disponible en la señal EMG para que el modelo pueda distinguirlo adecuadamente.

La Figura 6.3 muestra la evolución temporal de los ángulos reales y predichos por el modelo. Se

observa una alta concordancia especialmente en los dedos pulgar, índice y medio.




Figura 6.3: Comparación temporal entre los ángulos articulares reales (azul) y predichos (naranja) en un usuario visto.

Tabla 6-1: Resultados intrausuario por dedo (MAE, MSE, R^2)

Dedo	MAE (°)	MSE	Correlación
Pulgar	3.58	1.08	0.807
Índice	4.35	2.57	0.816
Medio	6.92	5.71	0.753
Anular	7.51	5.25	0.763
Meñique	6.27	3.87	0.795

6.2 Evaluación Interusuario

Para evaluar la generalización del sistema, se probó un sujeto nuevo utilizando dos configuraciones de entrenamiento:

- **Modelo de un solo usuario:** entrenado con datos de un único sujeto.
- **Modelo multisuarios:** entrenado con datos de 14 sujetos distintos.

La Figura 6.4 muestra el comportamiento del modelo entrenado con un solo usuario. Se observa un alto desajuste entre la señal real y la predicha, especialmente en los dedos índice y medio, indicando sobreajuste a un patrón específico.




Figura 6.4: Ángulos reales vs. predichos para un usuario no visto, usando modelo de un solo sujeto.

En cambio, la Figura 6.5 muestra cómo el modelo multisuarios mejora la precisión y el alineamiento temporal, lo que sugiere una mejor capacidad de generalización.




Figura 6.5: Ángulos reales vs. predichos para un usuario no visto, usando modelo entrenado con 14 sujetos.

Tabla 6-2: Comparación por dedo entre modelo de un usuario y multisuarios (MAE, MSE, R^2)

Dedo	1 usuario			14 usuarios		
	MAE (°)	MSE	Correlación	MAE (°)	MSE	Correlación
Pulgar	12.56	6.04	0.00	6.93	1.82	0.18
Índice	26.13	39.75	0.07	9.68	12.34	0.22
Medio	23.84	29.88	0.13	12.66	16.35	0.23
Anular	14.71	13.93	0.14	12.41	12.62	0.36
Meñique	9.87	10.65	0.28	10.16	10.38	0.28

6.3 Análisis por Gestos

Además de las evaluaciones realizadas por usuario, se llevó a cabo un análisis considerando los 25 gestos definidos en el Capítulo 4. En este caso se utilizaron todos los sujetos que formaron parte de la base de datos de entrenamiento, con el fin de revisar cómo se desempeña el modelo en cada gesto específico y

no solo en cada dedo por separado.

Para cada gesto se calculó el error promedio entre la predicción del modelo y el movimiento real, expresado en grados. También se incluyó la variación entre repeticiones del mismo gesto y un rango de confianza (IC95 %), que indica dónde se espera que se ubique el valor real del error en la mayoría de los casos. Estas medidas permiten observar no solo qué tan grande es el error, sino también qué tan estable es la predicción del modelo.

En la Tabla 6-3 se muestra la lista de gestos considerados, donde P = Pulgar, I = Índice, M = Medio, A = Anular y Me = Meñique. Cuando un dedo aparece indicado en la tabla, significa que dicho dedo se encuentra flectado.

Tabla 6-3: Equivalencia entre los identificadores numéricos y los gestos realizados en el estudio.

ID	Gesto
0	Reposo
1	Pulgar (P)
2	Índice (I)
3	Medio (M)
4	Anular (A)
5	Meñique (Me)
6	P + I
7	P + M
8	P + A
9	P + Me
10	I + M
11	M + A
12	A + Me
13	I + M + A
14	M + A + Me
15	P + A + Me
16	P + I + M
17	P + M + A
18	I + M + A + Me
19	P + M + A + Me
20	P + I + M + A
21	P + I + M + A + Me
22	$(P + I + M + A + Me) / 2$
23	Todos extendidos
24	I + A + Me
25	P + I + A + Me

La Figura 6.6 muestra el error promedio por gesto. Se observa que los gestos simples, como **reposo** (gesto 0) o la flexión de un único dedo (gestos 1–5), presentan los menores errores (aproximadamente entre 3 y 6), con rangos de confianza estrechos, lo que refleja mejores predicciones. En cambio, gestos más complejos, como la letra **L** (gesto 14) o la flexión de todos los dedos al mismo tiempo (gesto 21),

alcanzan errores mayores a 12 y muestran una mayor variación entre repeticiones.




Figura 6.6: Error promedio de cada gesto en grados, con intervalo de confianza al 95 % (IC95 %).

6.4 Discusión

En la evaluación intrausuario, el modelo obtuvo errores promedio (MAE) menores a 8° en todos los dedos, con el valor más bajo en el pulgar (3.58°) y el más alto en el anular (7.51°). Estos resultados indican que, en general, la diferencia entre lo predicho por el modelo y el valor real del ángulo fue reducida. El MSE también se mantuvo bajo, sin presencia de errores puntuales extremos. Se incluyó el cálculo del coeficiente de correlación de Pearson, con valores que variaron entre 0.75 y 0.82 en condición intrausuario. Esta métrica refleja qué tan bien las curvas predichas siguen la evolución temporal de los movimientos reales. En contextos donde se requiere representar o seguir el movimiento de los dedos en tiempo real, es más relevante que el modelo capture adecuadamente la tendencia y la forma del gesto a lo largo del tiempo, aunque los valores exactos de los ángulos no coincidan en todo momento con los medidos.

En la evaluación interusuario se observaron diferencias notables. Cuando el modelo fue entrenado únicamente con datos de un sujeto, los errores se incrementaron considerablemente, especialmente en el

dedo índice, donde el MAE alcanzó los 26.13° . En este caso, también se observaron correlaciones muy bajas (cercanas a 0), lo que evidencia que el modelo no logró adaptarse a los datos de una persona no vista. Sin embargo, al entrenar el modelo con datos de 14 sujetos diferentes, los errores disminuyeron en todos los dedos. Por ejemplo, en el índice el MAE bajó a 9.68° , y la correlación aumentó levemente a 0.22.

Por otra parte, el análisis por gestos permitió revisar cómo se comporta el modelo al reconstruir posturas completas de la mano. Los resultados mostraron que los gestos simples, como el reposo o la flexión de un solo dedo, tuvieron errores bajos ($3\text{--}6^\circ$) y se repitieron de manera bastante estable. En cambio, los gestos más difíciles, como la flexión de todos los dedos al mismo tiempo (gesto 21) o la combinación de medio+anular+meñique (gesto 14), tuvieron errores más altos ($12\text{--}16^\circ$). En el caso del gesto 14, el modelo fue inestable: a veces bajaba correctamente ambos dedos, otras veces solo uno, o incluso bajaba otros dedos que no correspondían. Esto muestra que, mientras los gestos simples son más fáciles de reconocer, los que combinan varios dedos todavía representan un desafío para el sistema.

Finalmente, se comprobó que el modelo puede tolerar ciertas variaciones en la posición de la pulsera. Cuando fue entrenado con datos obtenidos en sesiones donde el dispositivo se colocó en distintas posiciones, el rendimiento no se vio afectado de manera significativa. Esto sugiere que el modelo logró aprender patrones musculares que se repiten, incluso si la ubicación exacta de los sensores cambia ligeramente entre sesiones. Esta característica es relevante si se busca desarrollar un sistema que sea robusto y fácil de utilizar en la práctica.

Capítulo 7. Discusión y Conclusión

7.1 Discusión

El sistema construido incluye una pulsera modular impresa en 3D, la cual fue ensamblada de forma exitosa, integrando los sensores EMG, el sistema de adquisición y el módulo de alimentación en una estructura compacta. Durante las sesiones de prueba, el dispositivo se ajustó correctamente al antebrazo sin limitar la movilidad del usuario. Las correas permitieron mantener un contacto firme y constante entre los electrodos y la piel, lo que se reflejó en señales estables y sin interferencias notables. La distribución modular de los sensores facilitó tanto su instalación como la posibilidad de realizar ajustes o reemplazos. En conjunto, el prototipo demostró ser funcional, fácil de montar y suficientemente cómodo para su uso durante periodos prolongados. Además, el sistema incluye un módulo de adquisición inalámbrico y una interfaz gráfica para visualizar y registrar las señales en tiempo real.

En las pruebas con un mismo usuario, el modelo presentó errores promedio menores a 8° y correlaciones por sobre 0.75. Dado que estos errores corresponden a menos del 12 % del rango típico de movimiento de los dedos, se consideran suficientemente bajos para aplicaciones de reconstrucción gestual o control interactivo, donde lo importante es capturar la forma y dinámica del movimiento.

Sin embargo, al evaluar el sistema con personas no vistas durante el entrenamiento, el rendimiento disminuyó considerablemente. Esto indica que el modelo aún depende de haber visto datos similares previamente, y que le cuesta generalizar ante señales nuevas. Por ello, es fundamental entrenar con datos variados que incluyan diferentes personas y condiciones de uso, de modo que el modelo pueda aprender a reconocer mejor los distintos patrones musculares.

Además, se observó que el rendimiento del modelo bajaba cuando la pulsera se colocaba en una posición distinta a la usada durante el entrenamiento. No obstante, cuando se incluyeron sesiones con diferentes posiciones del dispositivo, el modelo funcionó con mejor rendimiento. Esto sugiere que entrenar con datos diversos puede mejorar la adaptabilidad del sistema a escenarios reales.

También se detectaron limitaciones en la capacidad del modelo para predecir ciertos gestos. Por un lado, hubo dificultades en aquellos que no formaron parte del entrenamiento o que requieren una baja activación muscular, como la letra **O**, donde las estimaciones no lograron emitir la forma circular esperada. Por otro lado, incluso en gestos incluidos en el entrenamiento, se observaron inconsistencias en

combinaciones complejas o con fuerte acoplamiento muscular entre dedos. Un ejemplo son los gestos 14 y 21, que alcanzaron errores promedio más altos ($12\text{--}16^\circ$) y mostraron mayor variabilidad, lo que indica que al modelo le resulta difícil predecir correctamente cuando varios dedos participan al mismo tiempo. Estas observaciones refuerzan la necesidad de ampliar la cobertura del set de entrenamiento, incorporar sesiones con mayor variabilidad y considerar mecanismos de adaptación o filtrado que permitan mejorar la estabilidad del sistema frente a gestos complejos.

Como alternativa complementaria, se propone implementar un proceso de calibración breve para nuevos usuarios, mediante técnicas de *transfer learning* o *fine-tuning*, que permitan ajustar el modelo con unos pocos minutos de datos personalizados, sin necesidad de reentrenar desde cero.

Si bien no se midió de forma exacta la latencia del sistema, durante las pruebas se observó una respuesta continua con una leve demora visual, estimada en menos de un segundo. Esta latencia no interrumpió el flujo del seguimiento ni impidió la visualización fluida de los movimientos, lo que indica que el sistema puede operar en condiciones cercanas al tiempo real.

7.2 Conclusión

Este trabajo demostró que es posible desarrollar un sistema funcional para estimar los movimientos articulares de los dedos de la mano utilizando únicamente señales electromiográficas superficiales (sEMG) registradas desde la muñeca. A diferencia de otros enfoques que requieren sensores distribuidos en el antebrazo o equipos ópticos complejos, esta propuesta entrega una solución más simple, portátil y no invasiva.

Se cumplieron todos los objetivos planteados: se diseñó y construyó una pulsera funcional con sensores EMG; se adquirieron y procesaron datos musculares sincronizados con ángulos articulares obtenidos mediante una cámara; se entrenó un modelo basado en redes neuronales convolucionales con atención y arquitectura multirramal; y se evaluó el rendimiento del sistema en tiempo real y en múltiples usuarios, tanto vistos como no vistos. La interfaz gráfica desarrollada permitió registrar, visualizar y validar simultáneamente las señales y predicciones.

Desde el punto de vista práctico, este sistema tiene potencial para ser utilizado en aplicaciones como control de prótesis, rehabilitación o interfaces gestuales, especialmente en entornos donde se requiere una solución de bajo costo, fácil de usar y portátil.

7.3 Trabajo Futuro

A futuro, se espera seguir mejorando el sistema desde el punto de vista técnico, por ejemplo, utilizando sensores EMG de diseño propio que entreguen señales más limpias, combinando la información muscular con sensores de movimiento, incorporando un sistema de calibración rápida para nuevos usuarios, o explorando el uso de sensores de alta densidad (HD-EMG) para obtener una lectura más detallada de la actividad muscular, especialmente cuando cambia la posición del dispositivo.

Además, se busca ampliar lo que el sistema puede hacer. Una de las próximas líneas de trabajo será avanzar hacia un traductor de letras en lengua de señas chilena (LSCh), aprovechando que el modelo ya es capaz de distinguir configuraciones específicas de los dedos. También se evaluará su funcionamiento en el otro brazo, se analizará cómo cambia su rendimiento después de un uso prolongado, y se medirá con mayor precisión la duración de la batería. Finalmente, se planea probar el sistema con personas amputadas para explorar su utilidad en escenarios reales de rehabilitación y control de prótesis.

Glosario

ADC Convertidor Análogo Digital

ANN Redes Neuronales Artificiales

BLE Bluetooth Low Energy

CNN Redes Neuronales Convolucionales

DIP Articulación Interfalángica Distal

EMG Electromiografía

Hz Hercios

MCP Articulación Metacarpofalángica

MCU Microcontrolador

PIP Articulación Interfalángica Proximal

ResNet Redes Neuronales Residuales

RNN Redes Neuronales Recurrentes

sEMG Electromiografía Superficial

SPS Muestras por Segundo

Referencias

- [1] F. Khadivar, V. Mendez, C. Correia, I. Batzianoulis, A. Billard, and S. Micera, “EMG-driven shared human-robot compliant control for in-hand object manipulation in hand prostheses,” *J Neural Eng*, vol. 19, no. 6, Dec. 2022.
- [2] C. labs at Reality Labs, D. Sussillo, P. Kaifosh, and T. Reardon, “A generic noninvasive neuromotor interface for human-computer interaction,” *bioRxiv*, 2024.
- [3] J. Li, Y. Liu, W. Xu, and Z. Li, “Gasla: Enhancing the applicability of sign language translation,” in *IEEE INFOCOM 2022 - IEEE Conference on Computer Communications*, 2022, pp. 1249–1258.
- [4] A. Phinyomark and E. Scheme, “A feature extraction issue for myoelectric control based on wearable emg sensors,” pp. 1–6, 2018.
- [5] Y. Liu, S. Zhang, and M. Gowda, “A practical system for 3-d hand pose tracking using emg wearables with applications to prosthetics and user interfaces,” *IEEE Internet of Things Journal*, vol. 10, no. 4, pp. 3407–3427, 2023.
- [6] C. Lugaresi, J. Tang, H. Nash, C. McClanahan, E. Uboweja, M. Hays, F. Zhang, C.-L. Chang, M. G. Yong, J. Lee, W.-T. Chang, W. Hua, M. Georg, and M. Grundmann, “Mediapipe: A framework for building perception pipelines,” 2019.
- [7] F. Hu, P. He, S. Xu, Y. Li, and C. Zhang, “Fingertrak: Continuous 3d hand pose tracking by deep learning hand silhouettes captured by miniature thermal cameras on wrist,” *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, vol. 4, pp. 1–24, 06 2020.
- [8] J. Cao, Y. Liu, L. Han, and Z. Li, “Finger tracking using wrist-worn emg sensors,” *IEEE Transactions on Mobile Computing*, vol. 23, no. 12, pp. 14 099–14 110, 2024.
- [9] S. Jacob, *Human Anatomy: A Clinically-Orientated Approach*. Edinburgh, London, New York, Oxford, Philadelphia, St. Louis, Sydney, Toronto: Elsevier, 2007.
- [10] TeachMeAnatomy, “Muscles of the posterior forearm,” 2024, accessed: 2024-10-08. [Online]. Available: <https://teachmeanatomy.info/upper-limb/muscles/posterior-forearm/>
- [11] TeachMeAnatomy, “Muscles of the anterior forearm,” 2024, accessed: 2024-10-08. [Online]. Available: <https://teachmeanatomy.info/upper-limb/muscles/anterior-forearm/>

- [12] I. A. Kapandji, *The Physiology of the Joints: The Upper Limb*, 6th ed. Philadelphia, PA, USA: Elsevier, 2019.
- [13] C. Guan, L. G. Hassebrook, D. L. Lau, and V. Yalla, “Near-infrared composite pattern projection for continuous motion hand–computer interaction,” *Journal of Visual Communication and Image Representation*, vol. 18, no. 2, pp. 141–150, 2007. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1047320306000794>
- [14] LibreTexts, “7.6c: Carpos, metacarpianos y falanges (la mano) - libretexts español,” https://espanol.libretexts.org/Salud/Anatomia_y_Fisiologia/Libro%3A_Anatom%C3%ADa_y_Fisiolog%C3%ADa_%28Sin_l%C3%ADmites%29/7%3A_Sistema_esquel%C3%A9tico_-_Partes_del_Esqueleto/7.6%3A_El_miembro_superior/7.6C%3A_Carpos%2C_Metacarpianos_y_Falanges_%28La_Mano%29, 2022, accedido el 22 de mayo de 2025.
- [15] R. Chowdhury, M. Reaz, M. Ali, A. Bakar, K. Chellappan, and T. Chang, “Surface electromyography signal processing and classification techniques,” *Sensors*, vol. 13, pp. 12 431–12 466, 2013.
- [16] P. Konrad, *The ABC of EMG: A Practical Introduction to Kinesiological Electromyography*. Noraxon Inc., USA, 2005.
- [17] P. Horowitz and W. Hill, *The Art of Electronics*, 3rd ed. New York, USA: Cambridge University Press, 2015.
- [18] J. Ganssle, *The Art of Designing Embedded Systems*. Elsevier, 2018.
- [19] W. Kester, *The Data Conversion Handbook*. Norwood, MA, USA: Analog Devices Inc, 2005.
- [20] M. R. Ahsan, M. Ibrahimy, and O. Khalifa, “Hand motion detection from emg signals by using ann based classifier for human computer interaction,” 04 2011.
- [21] IBM, “Convolutional neural networks,” <https://www.ibm.com/topics/convolutional-neural-networks>, 2024, accessed: 2024-10-08.
- [22] Z. Xu, J. Yu, W. Xiang, S. Zhu, M. Hussain, B. Liu, and J. Li, “A novel se-cnn attention architecture for semg-based hand gesture recognition,” *Computer Modeling in Engineering Sciences*, vol. 134, pp. 1–21, 08 2022.
- [23] Indeed, “What is an attention model?” <https://www.indeed.com/career-advice/career-development/attention-model>, accessed: 2024-10-08.

- [24] S. Woo, J. Park, J.-Y. Lee, and I. S. Kweon, “Cbam: Convolutional block attention module,” in *Proceedings of the European conference on computer vision (ECCV)*, 2018, pp. 3–19.
- [25] H. Lee, D. Kim, and Y.-L. Park, “Explainable deep learning model for emg-based finger angle estimation using attention,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 30, pp. 1162–1172, 2022.
- [26] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)*, 2016, pp. 770–778.
- [27] J. Hu, L. Shen, and G. Sun, “Squeeze-and-excitation networks,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 7132–7141.
- [28] R. Merletti and P. A. Parker, “The effect of electrode material on the quality of surface emg signals,” *Journal of Electromyography and Kinesiology*, vol. 11, no. 2, pp. 123–136, 2001.
- [29] T. Instruments, “Ina333: Precision, low power instrumentation amplifier,” <https://www.ti.com/product/INA333>, 2016, accedido el 22 de mayo de 2025.
- [30] E. A. Clancy and N. Hogan, “Relating agonist-antagonist electromyograms to joint torque during isometric, quasi-isotonic, nonfatiguing contractions,” *IEEE Transactions on Biomedical Engineering*, vol. 46, no. 6, pp. 667–677, 1999.
- [31] T. Instruments, “Tps6040x series: Low-power switched-capacitor voltage inverter,” <https://www.ti.com/lit/ds/symalink/tps60403.pdf>, 2015, accedido el 22 de mayo de 2025.
- [32] C. J. De Luca, “The use of surface electromyography in biomechanics,” *Journal of Applied Biomechanics*, vol. 13, no. 2, pp. 135–163, 1997.

UNIVERSIDAD DE CONCEPCIÓN – FACULTAD DE INGENIERÍA

RESUMEN DE MEMORIA DE TÍTULO

Departamento	: Departamento de Ingeniería Civil Eléctrica
Carrera	: Ingeniería Civil Biomédica
Nombre del memorista	: Jorge Américo Fritis Zacconi
Título de la memoria	: Predicción de la Posición de los Dedos de la Mano
a Partir de Electromiografía Superficial en Tiempo Real	
Fecha de la presentación oral	: 29 de Agosto 2025
Profesor(es) Guía	: Esteban Pino Quiroga
Profesor(es) Revisor(es)	: Carlos Medina Muñoz, Pablo Aqueveque Navarro
Concepto	:
Calificación	:

Resumen

La interacción humano–máquina requiere interfaces naturales y eficientes. Este trabajo propone un sistema para estimar posiciones articulares de los dedos a partir de señales electromiográficas (EMG) superficiales medidas en la muñeca. Se diseñó una pulsera impresa en 3D con cinco sensores EMG, un módulo de adquisición inalámbrico y una interfaz gráfica capaz de registrar y visualizar simultáneamente las señales musculares y los ángulos articulares obtenidos con MediaPipe.

Se construyó una base de datos con 25 gestos realizados por 15 usuarios en 10 sesiones, incluyendo variaciones en la colocación de los electrodos. Con estos datos se entrenó una red neuronal convolucional con mecanismos de atención y arquitectura multi-ramal, en la que cada rama se centra en un dedo. El modelo alcanzó errores angulares promedio inferiores a 8° y correlaciones mayores a 0.75 en condición intrausuario. En condición interusuario el rendimiento disminuyó, aunque mejoró al incorporar datos de varios sujetos, obteniendo errores de aproximadamente 10° y correlaciones de 0.25. Se concluye que el sistema es viable para aplicaciones prácticas si se entrena con datos propios del usuario o con una base suficientemente diversa. También se observó que el modelo es sensible a la posición de la pulsera, aunque este efecto puede reducirse incluyendo datos con distintas ubicaciones. Como líneas futuras se propone mejorar la calidad de las señales con sensores EMG propios, complementar la información con sensores inerciales, implementar un sistema de calibración rápida y explorar el uso de EMG de alta densidad para mayor resolución espacial.