

Escuela Superior Politécnica del Litoral

Facultad de Ingeniería en Mecánica y Ciencias de la Producción

Diseño e implementación de un sistema de entrenamiento para personas
protetizadas

INGE-3017

Proyecto Integrador

Previo la obtención del Título de:

Ingeniero en Mecatrónica

Presentado por:

Náger Rafael Naranjo Molina

Guayaquil - Ecuador

Año: 2025

Dedicatoria

Dedico este proyecto, en primer lugar, a mis padres, quienes con su amor incondicional y sus sacrificios han sido el sostén esencial de mi vida y la fuente más grande de inspiración. A mis hermanos mayores, por brindarme siempre su apoyo constante y acompañarme en cada etapa de este camino. Extiendo también esta dedicatoria a mis familiares, cuyas palabras de aliento me dieron la fortaleza necesaria para superar los momentos más desafiantes. Y, de manera especial, a mis amigos, cuya compañía, paciencia y motivación hicieron que todo este proceso resultara más llevadero y significativo.

Náger Naranjo

Agradecimientos

Expreso mi más profundo agradecimiento a mis tutores, así como al Laboratorio de Neuroimagen y Bioingeniería y a la ESPOL, por la confianza depositada en mí y por ofrecerme el respaldo y la orientación indispensables para la realización de este proyecto, su acompañamiento representó un pilar esencial en mi formación académica y en mi desarrollo personal a lo largo de estos años.

Náger Naranjo

Declaración Expresa

Yo Náger Rafael Naranjo Molina acuerdo y reconozco que:

La titularidad de los derechos patrimoniales de autor (derechos de autor) del proyecto de graduación corresponderá al autor, sin perjuicio de lo cual la ESPOL recibe en este acto una licencia gratuita de plazo indefinido para el uso no comercial y comercial de la obra con facultad de sublicenciar, incluyendo la autorización para su divulgación, así como para la creación y uso de obras derivadas. En el caso de usos comerciales se respetará el porcentaje de participación en beneficios que corresponda a favor del autor o autores.

La titularidad total y exclusiva sobre los derechos patrimoniales de patente de invención, modelo de utilidad, diseño industrial, secreto industrial, software o información no divulgada que corresponda o pueda corresponder respecto de cualquier investigación, desarrollo tecnológico o invención realizada por mí durante el desarrollo del proyecto de graduación, pertenecerán de forma total, exclusiva e indivisible a la ESPOL, sin perjuicio del porcentaje que me corresponda de los beneficios económicos que la ESPOL reciba por la explotación de mi innovación, de ser el caso.

En los casos donde la Oficina de Transferencia de Resultados de Investigación (OTRI) de la ESPOL comunique al autor que existe una innovación potencialmente patentable sobre los resultados del proyecto de graduación, no se realizará publicación o divulgación alguna, sin la autorización expresa y previa de la ESPOL.

Guayaquil, viernes 16 enero del 2026.

Náger Rafael Naranjo Molina

Evaluadores

Jorge Hurel, Ph.D.

Profesor de Materia

Jonathan León, M.Sc.

Tutor de proyecto

Resumen

Las prótesis mioeléctricas de miembro superior requieren que el usuario aprenda a generar patrones musculares consistentes para activar comandos de control, condición que puede dificultar la adaptación inicial y aumentar el riesgo de subuso o abandono. Este trabajo presenta el desarrollo de DynaTrain, un banco de entrenamiento físico y digital que permite la práctica guiada del control mioeléctrico antes de la entrega de la prótesis. El sistema integra adquisición sEMG con sensores uMyo, comunicación BLE hacia un módulo embebido, procesamiento local en una plataforma Jetson Nano, ejecución de gestos en una mano robótica basada en motores Dynamixel y un gemelo virtual para visualización interactiva mediante interfaz web. Se diseñaron perfiles protésicos dinámicos para emular configuraciones con distintos grados de libertad, y se implementó un pipeline de depuración y normalización de señales que incluye corrección de etiquetas, exclusión de segmentos inválidos y estandarización Z-Score por sesión. Como validación inicial, se entrenó un clasificador CNN-1D a partir de sesiones reales segmentadas por bloques y ventanas temporales, obteniendo desempeño global alto en el conjunto de prueba y evidenciando limitaciones asociadas al desbalance de clases y la variabilidad de duración real de los gestos. Los resultados sustentan la viabilidad del banco como plataforma de entrenamiento y registro objetivo, y delinean mejoras necesarias para robustecer segmentación, sincronización y evaluación clínica.

Palabras Clave: sEMG, prótesis mioeléctrica, banco de entrenamiento, gemelo virtual, rehabilitación.

Abstract

Upper-limb myoelectric prostheses require users to learn consistent muscle activation patterns to generate reliable control commands, which can hinder early adaptation and increase the risk of underuse or abandonment. This work presents DynaTrain, a physical and digital training bench that enables guided myoelectric control practice before prosthesis delivery. The system integrates sEMG acquisition using uMyo sensors, BLE communication to an embedded module, local processing on a Jetson Nano, gesture execution on a Dynamixel based robotic hand, and a virtual twin for interactive visualization through a web interface. Dynamic prosthetic profiles were designed to emulate configurations with different degrees of freedom. A data pipeline was implemented for signal cleaning and normalization, including label correction, removal of invalid segments, and per-session Z-score standardization. As an initial validation, a 1D-CNN classifier was trained using real sessions segmented into continuous blocks and time windows, achieving high overall performance on the test set while highlighting limitations related to class imbalance and gesture duration variability. The results support the feasibility of the bench as a training and objective logging platform and identify key improvements for segmentation robustness, real time synchronization, and clinical evaluation.

Keywords: sEMG, myoelectric prosthesis, training platform, digital twin, rehabilitation.

Índice general

Resumen	I
<i>Abstract</i>	II
Índice general	III
Abreviaturas	V
Simbología	VII
Índice de figuras	VIII
Índice de tablas.....	IX
Índice de planos.....	X
Capítulo 1	1
1.2 Descripción del Problema	3
1.3 Justificación del Problema	6
1.4 Objetivos.....	6
1.4.1 Objetivo general	6
1.4.2 Objetivos específicos.....	7
1.5 Marco teórico.....	7
1.5.1 Prótesis de miembro superior basadas en sEMG	7
1.5.2 Tipos de prótesis según GDL y actuadores	8
1.5.3 Sensores sEMG	10
1.5.4 Mecanismos de control en tiempo real y latencia	11
1.5.5 Modelos de IA para la inferencia de gestos.....	12
1.5.6 Comunicaciones, actuadores y seguridad funcional.....	13
1.5.7 Estado del arte de bancos de entrenamiento con gemelo virtual y exergames.....	13
Capítulo 2	16
2.1 Metodología.....	17
2.2 Selección de la alternativa de diseño	18
2.3 Proceso de diseño.....	19

2.4	Requerimientos y limitaciones de diseño	20
Capítulo 3	30
3.1	Resultados de Adquisición de Datos sEMG	31
3.2	Construcción del Dataset y Depuración.....	31
3.3	Consistencia temporal y segmentación por bloques	32
3.5	Normalización de señales	35
3.6	Generación de Ventanas para Aprendizaje Supervisado	36
3.7	Entrenamiento del modelo CNN.....	37
3.8	Evaluación cuantitativa del clasificador	38
3.9	Discusión: implicaciones para el sistema Dyna-Train.....	40
3.10	Limitaciones y mejoras inmediatas recomendadas.....	40
Capítulo 4	42
4.1	Conclusiones y recomendaciones.....	43
4.1.1	Conclusiones	43
4.1.2	Recomendaciones	43
Referencias	45

Abreviaturas

ADC	Convertidor Analógico–Digital
BLE	Bluetooth Low Energy
BOM	Bill of Materials
CAD	Diseño Asistido por Computadora
CNN	Convolutional Neural Network
CSV	Comma-Separated Values
DL	Deep Learning
DoF	Degrees of Freedom
DSP	Procesamiento Digital de Señales
EI	Edge Impulse
EMG	Electromiografía
ESP32-S3	Microcontrolador ESP32-S3 de Espressif
FIR	Finite Impulse Response
FSR	Force Sensitive Resistor
GDL	Grados de Libertad
GUI	Graphical User Interface
HIL	Hardware-in-the-Loop
HMI	Human–Machine Interface
IA	Inteligencia Artificial
IEEE	Institute of Electrical and Electronics Engineers
IMU	Unidad de Medida Inercial
JSON	JavaScript Object Notation
LDA	Linear Discriminant Analysis
LLC	Learner-Led Curriculum
LSTM	Long Short-Term Memory
MAV	Mean Absolute Value
ML	Machine Learning
Ninapro	Non-Invasive Adaptive Prosthetics
PCA9685	Controlador PWM de 16 canales
PR	Pattern Recognition
PWM	Pulse Width Modulation
QoS	Quality of Service

RMS	Root Mean Square
ROC	Receiver Operating Characteristic
ROM	Range of Motion
SDK	Software Development Kit
sEMG	surface EMG
SOP	Standard Operating Procedure
SVM	Support Vector Machine
TLC	Teacher-Led Curriculum
TTL	Transistor–Transistor Logic
UART	Universal Asynchronous Receiver–Transmitter
U2D2	Interfaz USB a DYNAMIXEL
VR	Virtual Reality
VRE	Virtual Reality Environment
WS	WebSocket
XL330	Serie de servomotores DYNAMIXEL XL330-M288-T

Simbología

A	Área
f	Frecuencia
F _s	Frecuencia de muestreo
g	Aceleración gravitacional
I	Corriente eléctrica
k	Constante de resorte
L	Longitud
m	Masa
n	Número de muestras
P	Potencia
R	Resistencia eléctrica
T	Período
t	Tiempo
T _s	Período de muestreo
V	Voltaje
x	Coordenada cartesiana en eje x
y	Coordenada cartesiana en eje y
z	Coordenada cartesiana en eje z
α	Ángulo
Δ	Incremento o variación
θ	Ángulo de articulación
μ	Media
σ	Desviación estándar
τ	Par/torque
φ	Fase
ω	Velocidad angular
η	Eficiencia
ρ	Densidad
ζ	Factor de amortiguamiento

Índice de figuras

Figura. 1.1.	4
Tasas de rechazo y no uso de prótesis de miembro superior.....	4
Figura. 1. 2.	9
Manos protésicas comerciales: (a) Vincent Hand; (b) i-Limb; (c) Taska Hand; (d) Bebionic Hand.	9
Figura. 1. 3.	10
Banda de tres sensores sEMG uMyo.....	10
Figura. 1. 4.	11
Mano antropomórfica, económica y eficiente para el aprendizaje robótico.	11
Figura. 1. 5.	14
Interfaz informática utilizada en el entrenamiento de clasificadores y en las pruebas de prótesis virtuales	14
Figura 2. 1.	21
Diagrama de bloques del diseño conceptual.	21
Figura 2.2.	22
Figura 2.3.	23
Figura 2.4.	24
Figura 2.5.	25
Figura 3.3.	33
Duración promedio de gestos por etiqueta.....	33
Figura 3.4.	35
Total de registros por gesto.	35
Figura 3.5.	36
Señal original vs. señal normalizada del canal emg1 en una sesión representativa	36
Figura 3.7.	38
Curvas de entrenamiento: Pérdida, Loss, y Precisión, Accuracy, para entrenamiento y validación.	38
Figura 3.8.	39
Matriz de confusión del clasificador CNN-1D.....	39

Índice de tablas

Tabla 1.....	5
Variables y restricciones medibles del sistema.	5
Tabla 2.1.....	17
Trazabilidad entre objetivos, método y evidencia.....	17
Tabla 2.2.....	18
Tabla 2.3.....	20
Tabla 2.4.....	28
Tabla 3.1.....	31
Protocolo de sesión empleado para la adquisición sEMG.	31
Tabla 3.2.....	32
Resumen cuantitativo de depuración del dataset.....	32
Tabla 3.3.....	33
Estadísticas de duración en número de muestras por gesto.....	33
Tabla 3.4.....	34
Conteo total de muestras por etiqueta.	34
Tabla 3.5.....	37
Parámetros de ventaneo utilizados para el modelado.....	37
Tabla 3.7.....	38
Métricas por clase.....	38

Índice de planos

Plano 1.....	50
Plano 2.....	51
Plano 3.....	54
Plano 4.....	55
Plano 5.....	56
Plano 6.....	57
Plano 7.....	58
Plano 8.....	59
Plano 9.....	60
Plano 10.....	61
Plano 11.....	62
Plano 12.....	63
Plano 13.....	64
Plano 14.....	65
Plano 15.....	66
Plano 16.....	67
Plano 17.....	68

Capítulo 1

1.1 Introducción

La pérdida parcial o total de la función de la mano afecta de manera significativa la autonomía, la participación laboral y la calidad de vida. En este contexto, la rehabilitación protésica ha evolucionado desde dispositivos mecánicos de operación simple hasta prótesis mioeléctricas *multigrip*, capaces de ejecutar múltiples patrones de agarre y gestos mediante el control a partir de señales musculares registradas en la superficie de la piel (electromiografía de superficie, sEMG). Este salto tecnológico ha sido impulsado por avances en reconocimiento de patrones y, más recientemente, por técnicas de aprendizaje profundo, que permiten mapear patrones mioeléctricos a clases de gestos discretos o a trayectorias articulares continuas con mayor tolerancia al ruido que el control directo convencional. Sin embargo, en escenarios reales persisten limitaciones asociadas con la variabilidad inter e intra-sujeto, como el desplazamiento de electrodos y la dependencia de la postura del miembro, factores que degradan el desempeño del sistema de control y su confiabilidad percibida por el usuario [1].

La evidencia clínica y tecnológica coincide en que las funciones avanzadas de una mano *multigrip* no se traducen automáticamente en desempeño funcional si el usuario no atraviesa un proceso de entrenamiento estructurado. Sin una práctica guiada y progresiva, aumenta el subuso y el riesgo de abandono, especialmente, cuando el control exige coordinación fina, consistencia de activaciones musculares y adaptación a cambios cotidianos, como la fatiga, la sudoración y el reposicionamiento de los electrodos. A pesar de ello, la implementación de rutinas intensivas con biorretroalimentación objetiva, criterios de progreso y métricas cuantificables continúa siendo limitada en la práctica cotidiana. En respuesta a esta brecha, el presente proyecto propone un banco de entrenamiento que integre una mano robótica multi eje accionada por servomotores *dynamixel*, adquisición de sEMG mediante sensores uMyo, y un gemelo virtual sincronizado con *serious games* orientados a rehabilitación, con el fin de acelerar el aprendizaje sensorimotor y favorecer la transferencia de habilidades hacia la prótesis definitiva [2].

En paralelo, el estado del arte en prótesis de mano se organiza, de forma general, en dos enfoques de diseño. El primero prioriza manos subactuadas y deformables, que simplifican el control y robustecen la estabilidad del agarre. El segundo enfoque apunta a manos altamente actuadas, que incrementan la destreza al costo de una mayor complejidad mecánica y computacional. La disponibilidad de actuadores compactos, buses de comunicación y

estrategias basadas en sinergias permite aproximar grados de libertad funcionales con menos actuadores que los estrictamente equivalentes a la mano humana, optimizando espacio, consumo y mantenibilidad. Incorporar estas tendencias en un entorno de entrenamiento pre-protésico habilita la configuración de perfiles de movilidad y restricciones de movimiento antes del acople definitivo al muñón, reduciendo iteraciones posteriores y facilitando la adaptación individual por paciente [3].

Desde una perspectiva de ingeniería biomédica, el banco propuesto se diseña bajo criterios verificables: adquisición inalámbrica por vía BLE con baja latencia, procesamiento e inferencia en Jetson Nano con desempeño consistente ante variaciones típicas de la señal sEMG, y control articular en tiempo real con una latencia extremo-a-extremo por debajo de umbrales perceptibles para el usuario. Adicionalmente, se plantea una interfaz humano-máquina con métricas objetivas de desempeño, exactitud de clasificación, tiempos de respuesta, repetibilidad y evolución por sesión, así como mecanismos de exportación de datos anonimizados para seguimiento clínico e investigación. Finalmente, el gemelo virtual incorpora un esqueleto articulado equivalente al hardware de la prótesis del paciente, sincronizándose con cinemáticamente con la mano robótica ambidiestra actuada con motores *Dynamixel*, proporcionando retroalimentación visual y apoyo al reaprendizaje motor mediante tareas gamificadas. En conjunto, estos elementos buscan reducir la brecha entre demostraciones de laboratorio y uso cotidiano, alineándose con recomendaciones reportadas para desempeño temporal y entrenamiento en la literatura [4].

Este trabajo desarrolla un banco de entrenamiento mioeléctrico orientado a clínicas y fabricantes de prótesis, para apoyar sesiones de práctica, evaluación y seguimiento del progreso del paciente. El alcance incluye adquisición de sEMG, inferencia de gestos en una API local y sincronización entre gemelo virtual y actuadores de una mano robótica; se excluyen la validación clínica a gran escala, procesos regulatorios y la certificación de un producto comercial final. El Capítulo 1 presenta contexto, problema, justificación, objetivos y marco teórico; el Capítulo 2 describe metodología de diseño, selección tecnológica, requisitos y protocolos; los capítulos posteriores reportan resultados, conclusiones y recomendaciones.

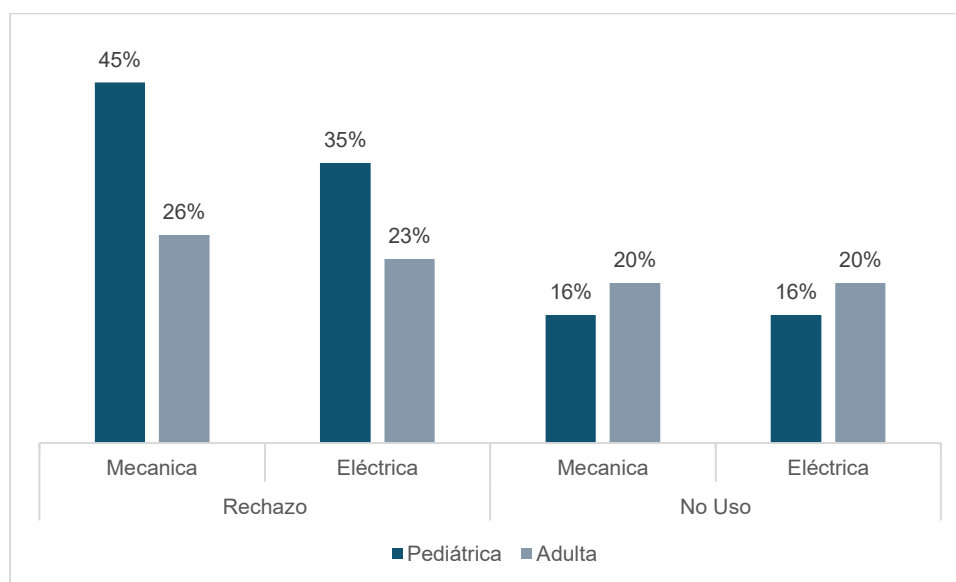
1.2 Descripción del Problema

A pesar del incremento en capacidades técnicas de las prótesis mioeléctricas *multigrip*, el desempeño funcional en condiciones reales de uso no se corresponde

consistentemente con el desempeño reportado en entornos controlados. Esta brecha se manifiesta en errores de activación, pérdida de control y baja percepción de agencia, especialmente durante las primeras etapas de adaptación, lo que incrementa la frustración del usuario y el riesgo de subuso o abandono [5].

Figura. 1.1.

Tasas de rechazo y no uso de prótesis de miembro superior.



Nota. La figura muestra las tasas de rechazo y no uso de prótesis de miembro superior de tipo mecánica y eléctrica en poblaciones pediátricas y adultas.

El control basado en sEMG presenta sensibilidad a factores que cambian entre sesiones y durante una misma sesión, variabilidad fisiológica inter e intra-sujeto, cambios de postura del miembro residual, sudoración y fatiga, así como desplazamiento y recolocación de electrodos. Estos factores alteran la distribución temporal y espectral de la señal y deterioran la exactitud de la clasificación o la estabilidad del control, provocando activaciones no deseadas y fallos de ejecución del gesto [5]. Adicionalmente, el desempeño percibido depende de restricciones de tiempo real: la cadena de adquisición de los datos, transmisión, inferencia y actuación debe mantener una latencia de extremo a extremo baja y estable, caso contrario, se degrada la fiabilidad del control y el seguimiento de tareas interactivas [6]. Los programas de entrenamiento existentes difieren en formato, duración e intensidad, con escasa estandarización de tareas y medición cuantitativa del progreso. Frecuentemente, el entrenamiento inicia después de la entrega del encaje definitivo, retrasando la familiarización del paciente con el conjunto de gestos y dificultando la

personalización temprana del esquema de control. Aunque la literatura reporta beneficios de realidad virtual, exergames y serious games para motivación y transferencia de habilidades, persiste la necesidad de plataformas integradas que sincronicen hardware físico y simulación con telemetría detallada, permitiendo evaluación reproducible y comparación entre sesiones [6]. Se requiere un banco de entrenamiento pre-protésico capaz de emular perfiles funcionales de distintas prótesis mediante una mano robótica configurable, integrada a un gemelo virtual y a tareas terapéuticas interactivas, que permita practicar antes del acople definitivo y registrar métricas objetivas de control voluntario. En consecuencia, el problema se operacionaliza mediante variables medibles y restricciones técnicas que aseguren reproducibilidad, seguridad y trazabilidad de resultados [7].

Tabla 1

Variables y restricciones medibles del sistema.

Variable / Restricción	Medición	Meta / Criterio
Exactitud De Inferencia	Porcentaje de aciertos por clase / Matriz de confusión	Mejorar respecto a línea base por sesión
Tiempo De Reacción	Ms desde estímulo visual hasta activación correcta	Disminución progresiva por sesiones
Latencia Extremo A Extremo	P95 de ms desde adquisición sEMG hasta movimiento observable	Baja y estable
Robustez De Recolocación Y Desplazamiento De Electrodo	Caída de exactitud vs condición nominal	Minimizar degradación
Pérdida De Paquetes Ble / Estabilidad De Enlace	Porcentaje de pérdida y <i>jitter</i> del intervalo	Baja perdida
Repetibilidad De Gesto	Variabilidad de posición final	Reducir variabilidad intra-sesión
Seguridad Funcional	Límites de corrientes y velocidad, eventos de parada	Cero eventos de sobrelímite en pruebas
Métricas De Sesión	Duración, intentos, tasa de éxito, ROM por articulación	Registro completo y anonimizado

1.3 Justificación del Problema

Disminuir la brecha entre capacidad técnica y desempeño real contribuye a mejorar autonomía y participación funcional, reduciendo frustración y facilitando la continuidad del uso de la prótesis. Dado que el entrenamiento es un factor determinante para aprovechar funciones *multigrip*, disponer de un entorno estructurado y medible impacta significativamente en la experiencia de adaptación del usuario y en su adherencia al proceso de rehabilitación [8]. Un banco estandarizado con tareas funcionales y métricas objetivas respalda decisiones de prescripción médica, ajuste y seguimiento clínico. La posibilidad de comparar desempeño entre sesiones, cuantificar progreso y detectar patrones de fallo, por postura o recolocación, fortalece la evaluación terapéutica y habilita intervención temprana antes de consolidar estrategias de control ineficientes [8].

Integrar reconocimiento de patrones y aprendizaje profundo sobre sEMG con telemetría en tiempo real permite estudiar robustez ante variaciones fisiológicas y de colocación de electrodos, además de evaluar estrategias de mitigación como protocolos multi-postura, enriquecimiento de datos y normalización temporal. Esto produce evidencia técnica transferible a diferentes diseños protésicos y facilita la evolución iterativa del sistema de control [9]. La integración de gemelo virtual y serious games no solo incrementa adherencia, sino que crea un marco experimental para recolectar datos anonimizados, analizar desempeño por sujeto y explorar enfoques *human-in-the-loop*. El banco, al ser modular y configurable, se convierte en una plataforma replicable para universidades y laboratorios, permitiendo comparar algoritmos y arquitecturas bajo condiciones controladas pero relevantes para el uso cotidiano [10, 11].

Se espera observar una reducción del tiempo de reacción durante tareas de entrenamiento, mejora de exactitud y estabilidad del reconocimiento de gestos por sesión, y menor degradación del desempeño frente a recolocación moderada de electrodos o cambios de postura, además de indicadores de usabilidad y percepción del control en una escala estandarizada [11].

1.4 Objetivos

1.4.1 Objetivo general

Diseñar un banco de entrenamiento para personas con amputación de miembro superior mediante la adquisición de señales de electromiografía superficial, control en tiempo

real de una mano robótica, representación de un gemelo virtual sincronizado y una interfaz de entrenamiento terapéutico interactiva, para la práctica y evaluación del control voluntario de diferentes configuraciones protésicas antes del acople definitivo.

1.4.2 Objetivos específicos

1. Diseñar una mano robótica basada en actuadores Dynamixel mediante la configuración de grados de libertad, rangos de movimiento y límites seguros de corriente y velocidad, para la simulación de perfiles funcionales de distintas prótesis.
2. Modelar un gemelo virtual articulado en Blender mediante la vinculación en tiempo real de los comandos articulares y la telemetría de la mano robótica, para la presentación de instrucciones visuales y tareas funcionales al paciente durante las rutinas de entrenamiento.
3. Desarrollar una interfaz gráfica mediante la gestión estructurada de sesiones de entrenamiento, la ejecución de *exergames*, la visualización de retroalimentación y el registro de métricas anonimizadas, para el seguimiento clínico y el análisis posterior.
4. Implementar un modelo de clasificación de patrones en una Jetson Nano junto con recepción de datos sEMG vía BLE con el ESP32, para la inferencia en vivo y adaptación del desempeño por sujeto.

1.5 Marco teórico

1.5.1 Prótesis de miembro superior basadas en sEMG

Las prótesis mioeléctricas modernas traducen patrones de activación muscular captados con sEMG en comandos de control para manos y muñecas protésicas. El enfoque clásico de control directo con dos electrodos ofrece funciones limitadas, mientras que los esquemas PR extraen información multicanal y la clasifican en gestos o modos, habilitando control multifunción más intuitivo. Revisiones de referencia describen la evolución de estas técnicas, sus etapas de preprocesamiento, extracción de características y clasificación, y los retos de robustez en condiciones reales de uso [12].

El surgimiento de repositorios abiertos ha permitido comparar métodos y acelerar el progreso. La base de datos Ninapro reúne señales sEMG de sujetos sanos y amputados, con protocolos estandarizados de movimientos y validación técnica, lo que la convierte en un pilar

para estudios comparativos de algoritmos y para el diseño de *benchmarks* reproducibles. La literatura enfatiza que, aunque se alcanzan altas exactitudes en escenarios controlados, persisten errores en actividades cotidianas, por lo que la transferencia del laboratorio a la clínica exige estrategias de entrenamiento y calibración centradas en el usuario [13].

En términos de desempeño, las tasas de clasificación reportadas en condiciones de laboratorio suelen superar el 80 % y, en casos específicos, el 90 %; no obstante, variaciones fisiológicas, de posicionamiento de electrodos y de postura degradan la robustez. Estas observaciones han motivado esquemas de adquisición más ricos, protocolos de entrenamiento por múltiples posturas y, en algunos casos, la integración de sensores inerciales para compensar efectos posturales, aunque su adopción clínica aún es dispar [14].

Una implicación clave para bancos de entrenamiento es que la práctica temprana y guiada, junto con la recolección estructurada de datos durante el entrenamiento, puede simultáneamente mejorar el desempeño humano y actualizar modelos de control. El proyecto presente se alinea con esta línea, proponiendo un entorno de práctica con gemelo virtual y mano robótica, capaz de registrar métricas objetivas y habilitar estrategias de *human-in-the-loop learning* [13, 14].

En síntesis, la literatura evidencia que el control por sEMG permite control multifunción mediante PR y aprendizaje profundo, pero su desempeño se ve limitado por variabilidad fisiológica, postura y recolocación de electrodos, especialmente fuera de laboratorio [12, 14]. Esta limitación justifica la necesidad de un entorno de entrenamiento que recolecte datos estructurados y permita práctica guiada con métricas objetivas. El presente proyecto aborda este vacío mediante un banco que integra entrenamiento interactivo, gemelo virtual y telemetría del hardware para evaluar desempeño y robustez durante la adaptación.

1.5.2 Tipos de prótesis según GDL y actuadores

Las manos protésicas pueden clasificarse por su arquitectura mecánica y GDL: desde diseños monoarticulados hasta manos multigrado con dedos independientes o sinergias bajo-actuadas. Revisiones de ingeniería detallan compromisos entre par disponible, velocidad, masa, consumo, robustez y facilidad de control, así como tendencias hacia diseños bajo-actuados con conformidad mecánica que facilitan agarres robustos con control simplificado [15].

Figura. 1. 2.

Manos protésicas comerciales: (a) Vincent Hand; (b) i-Limb; (c) Taska Hand; (d) Bebionic Hand.



Nota. Imagen reproducida de [22], © IEEE, 2025.

Las manos basadas en tendones y sinergias, por ejemplo, líneas inspiradas en *SoftHand*, aprovechan la deformación permisible, *compliance*, para adaptarse al objeto, reduciendo la demanda de control sin sacrificar funcionalidad. Esta filosofía ha sido probada en aplicaciones asistidas y de rehabilitación, y es relevante para bancos de entrenamiento que deban emular diferentes perfiles de prótesis con límites de posición, velocidad y corriente [16].

Para prototipos y bancos de ensayo, actuadores modulares como DYNAMIXEL XL330-M288-T ofrecen control de posición, velocidad y corriente, telemetría integrada y bus serie TTL de medio dúplex con Protocolo 2.0; estos motores permiten configurar perfiles que reproduzcan restricciones de prótesis reales. El módulo U2D2 posibilita la interfaz PC-bus con hasta 6 Mbps, útil en la etapa de desarrollo y pruebas *hardware-in-the-loop* [15, 16].

La evidencia de diseño muestra el compromiso entre destreza, robustez, consumo y complejidad, destacando la utilidad de enfoques sub-actuados y estrategias de sinergias para lograr funcionalidad con menor demanda de control [15, 16]. Sin embargo, estos compromisos rara vez se incorporan en plataformas de entrenamiento pre-protésico configurables. El banco propuesto cubre esta brecha de investigación al permitir emulación de perfiles de prótesis mediante límites de GDL, corriente y velocidad, posibilitando entrenamiento alineado al dispositivo objetivo.

1.5.3 Sensores sEMG

La sEMG se capta con electrodos superficiales colocados sobre vientres musculares; su fidelidad depende de impedancia piel-electrodo, distancia inter-electrodo, orientación respecto a fibras y blindaje frente a interferencias. Las recomendaciones SENIAM y tutoriales de referencia detallan geometrías, preparación de piel, distancias típicas de 20 mm y bandas de frecuencia útiles entre 20 y 450 Hz, asegurando comparabilidad entre estudios y calidad de señal para control en tiempo real [17].

El preprocesamiento típico incluye remoción de componente DC, filtrado paso-banda, rectificación absoluta y suavizado de la envolvente, como por ejemplo el filtro paso-bajo de 10 Hz, además de normalización por sujeto. Estas etapas mejoran la relación señal-ruido, estabilizan amplitudes y habilitan estimación proporcional de esfuerzo. La literatura ofrece guías prácticas para su implementación y advierte de artefactos de movimiento, *crosstalk* entre músculos y ruido de red [17].

Figura. 1. 3.

Banda de tres sensores sEMG uMyo.



Nota. Imagen reproducida de [18], © IEEE, 2025.

Un factor crítico para la robustez es el efecto de posición del miembro, cambios en postura y carga reclutan combinaciones musculares distintas y alteran la distribución espectral de la sEMG, reduciendo la exactitud de los clasificadores entrenados en una sola postura. Estrategias de mitigación incluyen entrenar en múltiples posturas y, opcionalmente, medir postura con acelerómetros para *domain adaptation*. Aunque el presente proyecto prescinde de

IMU en su fase inicial, el banco de entrenamiento deberá contemplar protocolos multi-postura a través de los exergames [19].

Las guías técnicas enfatizan que la calidad de la sEMG depende de colocación, preparación de piel y control de interferencias, y que el efecto de postura puede degradar clasificadores entrenados en condiciones restringidas [17, 19]. No obstante, muchos flujos de entrenamiento no controlan sistemáticamente estas variables ni registran su impacto sesión a sesión. Por ello, el proyecto incorpora protocolos de adquisición y tareas multi-postura con registro de métricas, con el objetivo de mejorar reproducibilidad y robustez del control.

1.5.4 Mecanismos de control en tiempo real y latencia

El pipeline PR clásico comprende segmentación temporal por ventanas, extracción de características de tiempo y frecuencia, clasificación y generación de comandos, con la posibilidad de control proporcional a partir de la envolvente. Los investigadores Hudgins y col. establecieron un conjunto de características de referencia ampliamente replicado durante décadas, revisiones recientes lo sitúan como base frente a enfoques de *deep learning* [20].

Para operación clínica, la latencia extremo-a-extremo debe mantenerse baja y estable. En enlaces de adquisición inalámbrica, BLE ofrece consumo contenido con retardos típicos de decenas de milisegundos según intervalo de conexión, tamaño de paquete y condiciones de radio; estudios de rendimiento caracterizan su *throughput* y latencia, guiando la elección de parámetros. En el lado de actuadores, el bus TTL *half-duplex* de *Dynamixel* permite comandos y lectura de telemetría con tiempos de ida y vuelta acotados a altas tasas de *baud* [21].

Figura. 1. 4.

Mano antropomórfica, económica y eficiente para el aprendizaje robótico.



Nota. Imagen reproducida de [21], © IEEE, 2025.

La ejecución *on-device* de modelos ligeros en microcontroladores es hoy viable con TinyML. Evaluaciones recientes para sEMG muestran que arquitecturas compactas cuantizadas pueden cumplir objetivos de latencia y energía en MCUs, manteniendo exactitudes competitivas frente a servidores, lo que favorece un lazo de control cerrado con $p95 < 80$ ms en aplicaciones bien diseñadas [21].

La literatura sugiere que el desempeño interactivo depende de mantener baja y estable la latencia extremo-a-extremo, lo que obliga a diseñar la cadena BLE, inferencia y actuación con presupuestos temporales claros [20, 21]. En la práctica, muchos sistemas reportan exactitud sin reportar latencia p95 o jitter, dificultando comparaciones. Este proyecto integra medición de latencia y telemetría en el banco para asegurar trazabilidad entre diseño y desempeño.

1.5.5 Modelos de IA para la inferencia de gestos

Los esquemas PR tradicionales emplean clasificadores lineales o SVM sobre características de ventana; su fortaleza radica en la interpretabilidad y baja carga computacional, pero muestran sensibilidad a desplazamientos de electrodos y variaciones de postura. Revisiones de *deep learning* reportan avances con CNN para extracción automática de características, y LSTM o modelos con atención para dependencias temporales, mejorando la generalización intersujeto cuando existe suficiente entrenamiento y regularización [22].

Nuevas líneas investigan *transformers* y estrategias de adaptación de dominio, buscando invariancia a posición del miembro y a cambios día-a-día. El uso de datos de bases públicas, más colecciones propias con sujetos amputados, resulta clave para evitar sobreajuste a voluntarios sanos y habilitar despliegues clínicos. Estas técnicas se integran de manera natural en un banco de entrenamiento que recolecta datos durante el uso para recalibración incremental [23].

El diseño del conjunto de gestos y de las métricas de desempeño debe considerar exactitud, tiempo de reacción, estabilidad del control proporcional y fatiga. Protocolos de evaluación propuestos en bases como Ninapro y en estudios clínicos ofrecen marcos comparables y permiten medir transferencia de habilidades desde entornos virtuales hacia tareas funcionales [23].

Si bien los modelos tradicionales ofrecen baja carga computacional, los enfoques del aprendizaje profundo mejoran la generalización bajo ciertas condiciones, aunque siguen siendo sensibles a cambios día a día y de dominio [22, 23]. Se identifica como necesidad la recolección longitudinal y la evaluación con métricas comparables. El banco propuesto habilita esta evaluación al registrar desempeño por sesión y permitir actualización y experimentación controlada con modelos embebidos.

1.5.6 Comunicaciones, actuadores y seguridad funcional

Los actuadores DYNAMIXEL XL330 permiten fijar límites de corriente, velocidad y posición, registrar temperatura y corriente, y ejecutar paradas de emergencia por software, aspectos críticos para sesiones de entrenamiento seguras. La disponibilidad de telemetría habilita biorretroalimentación objetivo y el registro longitudinal de métricas en la HMI. La documentación del fabricante detalla control tables, rangos y modos de operación necesarios para mapear perfiles de prótesis [24].

El convertidor U2D2 facilita pruebas con PC y flujos *hardware-in-the-loop*, aunque en operación final puede sustituirse por un MCU con UART TTL compatible. Esta modularidad permite que el banco emule diferentes prótesis restringiendo GDL y perfiles cinemáticos, sin rediseñar electrónica de potencia [24].

En el eslabón de adquisición, la configuración de BLE, intervalo de conexión, MTU, número de notificaciones por intervalo, debe elegirse para lograr latencias bajas con pérdidas de paquete menores al 5 %, en concordancia con los requerimientos de entrenamiento y con el presupuesto de tiempo desde la adquisición sEMG hasta la ejecución del movimiento. Las caracterizaciones de BLE en aplicaciones biomédicas orientan estos *trade-offs* [25].

La telemetría y límites de seguridad en actuadores permiten diseñar sesiones seguras y medir esfuerzo mecánico asociado al entrenamiento [24, 25]. Sin embargo, estos parámetros rara vez se integran como métricas terapéuticas en plataformas de entrenamiento. El banco propuesto incorpora control y registro de corriente, velocidad y eventos de seguridad para apoyar decisiones clínicas y de diseño.

1.5.7 Estado del arte de bancos de entrenamiento con gemelo virtual y exergames

La rehabilitación y el entrenamiento protésico han adoptado serious games para aumentar motivación, adherencia y tiempo efectivo de práctica. Estudios pioneros demostraron

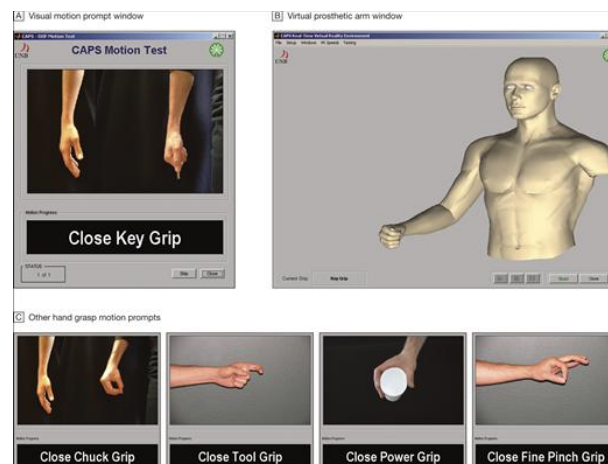
que juegos diseñados para control mioeléctrico mejoran métricas de desempeño y compromiso del usuario a corto plazo, perfilando pautas de diseño de *gameplay* y retroalimentación visual. Investigaciones recientes evalúan elementos de diseño de juegos en *VRE* y su efecto en control motor, variando tareas, dificultad adaptativa y tipos de retroalimentación. Resultados sugieren que la personalización del desafío, la progresión y la claridad de objetivos incrementan transferencia de habilidad, apoyando la inclusión de exergames parametrizables en bancos de entrenamiento [26].

Una línea de trabajo clave compara entrenamiento basado en juegos con métodos convencionales, mostrando que la combinación de control por *machine learning* y práctica lúdica puede igualar o superar intervenciones estándar en métricas funcionales, carga de trabajo y motivación. La recomendación emergente es integrar medición objetiva y *dashboards* de progreso, funciones que el presente proyecto contempla [27].

Estudios orientados a la transferencia de habilidades desde entornos virtuales han evidenciado mejoras en control funcional tras periodos de práctica con *VRE*. Dichas evidencias justifican la presencia de un gemelo virtual sincronizado con la mano robótica para cerrar el ciclo percepción, acción y retroalimentación, y acelerar la curva de aprendizaje [28].

Figura. 1. 5.

Interfaz informática utilizada en el entrenamiento de clasificadores y en las pruebas de prótesis virtuales



Nota. Imagen reproducida de [27], © IEEE, 2025.

En población pediátrica y juvenil, se han propuesto plataformas de juegos que ajustan dinámicamente contenidos según desempeño, manteniendo el interés y la dificultad apropiada,

una idea aplicable a adultos mediante progresiones de complejidad y objetivos por sesión. La comunidad *HCI* ha publicado diseños de juegos abiertos para entrenamiento mioeléctrico, proporcionando *toolkits* y pautas de usabilidad que facilitan replicación y extensión. Esto respalda una arquitectura modular donde *Unity* gestione gráficos 3D y tareas, mientras un servidor local registre métricas y maneje sesiones [28].

Sistemas de rehabilitación no inmersivos, como ReHabgame, integran sensores comerciales de gesto con motores de juego, destacando la importancia de medir compromiso y resultados con escalas estandarizadas. Aunque no están orientados exclusivamente a prótesis, aportan lecciones de diseño transferibles [29]. Se han explorado formatos móviles y *home-based*, abriendo la puerta a tele-entrenamiento. Para un banco de laboratorio, estas evidencias permiten planificar una fase posterior de deslocalización de las sesiones, preservando adquisición segura de datos y privacidad [29]. Trabajos recientes discuten limitaciones de muchos serious games actuales, destacando la necesidad de objetivos terapéuticos claros, métricas válidas y realismo de tareas; el proyecto propuesto responde con registro de rangos de movimiento, tiempos de reacción y *dashboards* para terapeutas [30]. Finalmente, emergen propuestas de gemelo digital en rehabilitación, donde el modelo virtual replica estado y comandos del dispositivo, posibilitando análisis de trayectoria, *what-if* y personalización del plan de entrenamiento. Este concepto guía la integración del modelo articulado virtual y mano robótica del presente banco [31].

Capítulo 2

2.1 Metodología

En este capítulo se describió el procedimiento seguido para cumplir los objetivos del proyecto. Se documentaron las decisiones de diseño desde la selección de la arquitectura de procesamiento hasta la definición de requerimientos verificables y la partición del sistema en módulos mecánicos, eléctricos, de software y control. Asimismo, se estableció el protocolo de recolección de datos sEMG, el método de entrenamiento y despliegue del modelo de inferencia, y las consideraciones éticas, legales y de seguridad funcional aplicables al banco de entrenamiento.

Con el fin de asegurar trazabilidad entre el planteamiento del problema y la implementación, cada etapa metodológica se vinculó a los objetivos específicos, incluyendo el tipo de evidencia que se generó y el capítulo donde se reportó. En la Sección 2.1 se justificó la alternativa de arquitectura seleccionada, en la Sección 2.2 se describió el proceso iterativo de diseño, en la Sección 2.3 se formalizaron requerimientos y restricciones en una matriz verificable, en las Secciones 2.4 a 2.15 se detalló el diseño conceptual y la selección de componentes, y finalmente, en las Secciones 2.16 y 2.17 se integraron las consideraciones éticas y la estrategia de identificación para el análisis de resultados.

Tabla 2.1.

Trazabilidad entre objetivos, método y evidencia.

Objetivo Especifico	Método Aplicado	Evidencia
Mano robótica	Diseño mecánico, parametrización de actuadores y límites seguros	Planos, ensambles, parámetros de seguridad, validación de movimientos y topes mecánicos.
Gemelo Virtual	Modelado en Blander, integración en interfaz visual y enlace en tiempo real	Prueba de sincronización, captura de trayectorias
Interfaz y sesiones	Frontend web y backend local, registro de métricas	<i>Dashboard</i> , exportación de sesiones, logs y métricas por sesión
Adquisición BLE e inferencia	ESP32 como <i>Gateway</i> hacia API local y modelo <i>TFLite</i>	Métricas de exactitud, matriz de confusión, latencia p95, robustez de recolocación

2.2 Selección de la alternativa de diseño

Se compararon tres arquitecturas de referencia para implementar un banco de entrenamiento mioeléctrico:

- A. **Procesamiento embebido en microcontrolador:** adquisición, preprocesamiento e inferencia en el dispositivo.
- B. **Inferencia en servidor local:** dispositivo de adquisición como *Gateway*, inferencia y registro en un servidor local.
- C. **Inferencia en la nube:** envío de datos a un servicio remoto para inferencia y almacenamiento.

La selección se realizó con base en criterios de desempeño, autonomía y mantenibilidad, priorizando un control interactivo con latencia acotada y operación sin dependencia de conectividad externa.

Tabla 2.2.

Comparación de alternativas de arquitectura.

Criterio	A. Embebido	B. Servidor Local	C. Nube
Latencia extremo a extremo	Muy baja	Baja y controlable	Variable
Autonomía sin internet	Alta	Alta	Baja
Complejidad de despliegue	Alta	Media	Baja
Registro de telemetría y panel clínico	Bajo, limitado por recursos	Alto, flexible	Alto, dependiente de la red
Mantenibilidad	Media	Alta	Media
Escalabilidad	Media	Alta	Alta
Seguridad y control de datos	Alto	Alto	Medio

Dado el requisito de latencia extremo-a-extremo inferior a 80 ms en el percentil 95, la necesidad de operar sin conectividad a Internet y la conveniencia de registrar la telemetría detallada para su seguimiento clínico, se seleccionó la alternativa B, Servidor Local. La alternativa A se mantuvo como línea futura, condicionada a la simplificación del modelo y su despliegue mediante cuantización a 8 bits cuando se requiriera un acoplamiento aún más embebido.

Para alojar la API de inferencia se evaluaron como candidatos un computador convencional y una Nvidia Jetson Nano 2 GB. Se priorizó el uso de la *Jetson Nano* por la mayor integración de *edgeimpulse* y aceleración por GPU. En el subsistema de actuación se priorizó la familia Dynamixel XL330-M288-T por su comunicación TTL con Protocolo 2.0, control de posición, velocidad, corriente, telemetría integrada y dimensiones adecuadas para una mano robótica de entrenamiento. La interfaz U2D2 facilitó la integración del bus de comunicación y la distribución de potencia desde una fuente externa regulada de 5V 5A. Para evitar que el umbral de latencia quedara como afirmación aislada, se definió la medición de latencia extremo-a-extremo mediante sellos de tiempo en tres puntos referenciales, la recepción de ventana sEMG en el servidor, respuesta de inferencia generada por la API y la ejecución del comando en el actuador controlada por telemetría. Se reportaron p50 y p95, además de jitter, en el capítulo de resultados.

2.3 Proceso de diseño

Se siguió un proceso iterativo para sistemas mecatrónicos y de software: definición de requisitos medibles, diseño conceptual, prototipado rápido, verificación por módulo y validación integrada con usuarios piloto. Se incorporaron principios de diseño centrado en el usuario para sistemas interactivos según la normativa ISO 9241-210 [32], en el desarrollo de la interfaz HMI, *Human-Machine Interface*, de paciente y clínico. La ingeniería de software se organizó en *backend* desarrollado en *Python* para adquisición, preprocesamiento e inferencia, y en *frontend web* para HMI, visualización de entrenamientos y panel de métricas, empleando Vite, React 19, TypeScript y Tailwind CSS. El flujo de datos se estructuró en las siguientes etapas.

- Captura de datos sEMG a 1.000 Hz.
- Filtrado pasobanda y rectificación.
- Extracción de envolvente.
- Normalización y ventana deslizante para el clasificador CNN.

Esta secuencia se reporta como la más recomendada para sEMG. Para la instrumentación ética y legal se adoptaron los lineamientos del Reglamento General de Protección de Datos, GDPR, para datos personales [33], junto con los principios del Informe Belmont para investigación con personas [34]. Se definieron procedimientos de consentimiento informado, anonimización y resguardo de datos, y se planificó la revisión por un comité de ética antes de las pruebas con pacientes.

2.4 Requerimientos y limitaciones de diseño

Se formalizaron los requerimientos y restricciones como una matriz verificable para asegurar trazabilidad hacia la validación experimental. Los requisitos se definieron con una métrica, un método de verificación y el tipo de evidencia esperada.

Tabla 2.3.

Matriz de requerimientos verificables.

ID	Requisito	Métrica	Verificación
R-01	Latencia extremo a extremo	P50 y p90 desde recepción de ventana hasta ejecución	Instrumentación con sellos de tiempo y telemetría
R-02	Exactitud de clasificación	Accuracy y F1 por clase	Validación con partición definida y matriz de confusión
R-03	Estabilidad de conexión BLE	Porcentaje de pérdida de paquetes, jitter	Registro de paquetes, heartbeats y reconexión
R-04	Seguridad funcional de actuadores	Cumplimiento de límites de corriente, velocidad y posición	Verificación de límites y eventos de fallo
R-05	Soporte de perfiles protésicos	Perfiles configurables	Configuración en HMI y prueba de ejecución

2.5 Diseño Conceptual

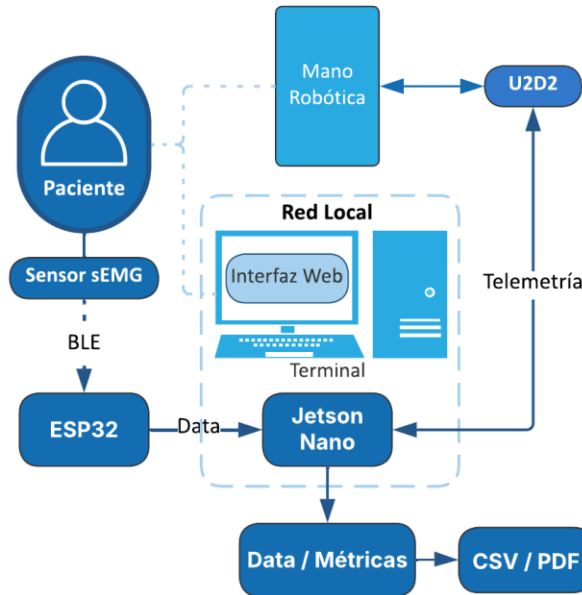
El sistema quedó particionado en cinco módulos:

- 1) Adquisición sEMG con sensores EMG.
- 2) Preprocesamiento e inferencia en servidor local.
- 3) Controlador de actuadores XL330 vía U2D2.
- 4) Gemelo virtual sincronizado.
- 5) HMI dual paciente-clínico.

El diagrama de bloques se resume a continuación:

Figura 2. 1.

Diagrama de bloques del diseño conceptual.



Nota. Elaboración propia, © IEEE, 2025.

El gemelo virtual se diseñó con esqueletos articulados importados desde Blender, parametrizados para reflejar los grados de libertad de acuerdo con la prótesis emulada. La interfaz gráfica del paciente mostró instrucciones y retroalimentación en tiempo real, mientras la interfaz del rol clínico permitió iniciar sesiones y exportar datos anonimizados. Se definió un protocolo de calibración guiada al inicio de cada sesión: verificación de electrodos, prueba de contracciones musculares breves para estimar niveles de referencia y ajuste de umbrales de aceptación de predicciones, con visualización de envolventes por canal en la interfaz como control de calidad de señal previo al entrenamiento.

2.6 Parámetros de diseño mecánico

Se dimensionaron dedos y palma de la mano robótica con proporciones antropométricas de una mano adulta, y se organizaron acoples impresos en PLA para fijar motores XL330 en disposición de simetría al plano frontal de modo que permitan emular distintos grados de libertad, rangos de movimiento y la configuración tanto de una mano diestra como zurda. La ubicación de cada motor siguió la distribución anatómica natural de las articulaciones metacarpianas, tomando como referencia una radiografía anteroposterior de la mano. Las longitudes promedio de las falanges y los metacarpos se obtuvieron de Buryanov y Kotiuk [35], cuyos datos antropométricos

servieron como base para el dimensionamiento. Estas proporciones se conservaron ajustándolas a las dimensiones de los motores mediante la aplicación de un factor de escala de 1,85, lo que permitió mantener la relación geométrica característica de una mano real. Se consideró el par nominal y límite de corriente de los XL330 para definir relaciones geométricas de acoples y ejes internos, con el fin de operar dentro de la zona segura. Se establecieron topes mecánicos para proteger ante comandos erróneos y se definieron factores de seguridad frente a sobrecargas y picos de corriente. Los ensambles se validaron con simulaciones rápidas de interferencia antes del primer montaje con actuadores. Se diseñó un soporte de mesa rígido para la mano robótica, el controlador U2D2, la Jetson Nano, la fuente DC y canalización de cables, con cubierta protectora simulando ser un antebrazo en proporción adecuada, manteniendo ergonomía del usuario frente a la pantalla.

Figura 2.2.

Radiográfica anteroposterior de la mano con magnitudes medidas.



Nota. Imagen reproducida de [35], © IEEE, 2025.


2.7 Selección de sensores sEMG

Con el propósito de adquirir señales sEMG multicanal en condiciones portátiles, se seleccionaron tres sensores uMyo debido a su adquisición diferencial, formato encapsulado, conectividad BLE y disponibilidad de unidad inercial integrada para una posible reincorporación

de variables de orientación en fases posteriores. De acuerdo con las especificaciones del fabricante, los sensores operaron como módulos autoalimentados mediante una batería recargable de polímero de litio de una celda y transmitieron datos en formato digital vía BLE. Como instrumento de referencia para pruebas comparativas y procesos de calibración, se empleó adicionalmente un sensor analógico *Gravity* EMG de DFRobot. Este dispositivo permitió contrastar la cadena de acondicionamiento y preprocesamiento, especialmente en lo relativo a filtrado y estabilidad de la señal, frente a las lecturas obtenidas con los sensores digitales. La estrategia de colocación de electrodos y la preparación de la piel se definieron con base en recomendaciones *SENIAM* para músculos del antebrazo y se documentaron de manera específica en la sección de protocolo de adquisición.

Figura 2.3.

Diagrama de potencia y carga de uMyo.



Nota. Imagen reproducida de [18], © IEEE, 2025.

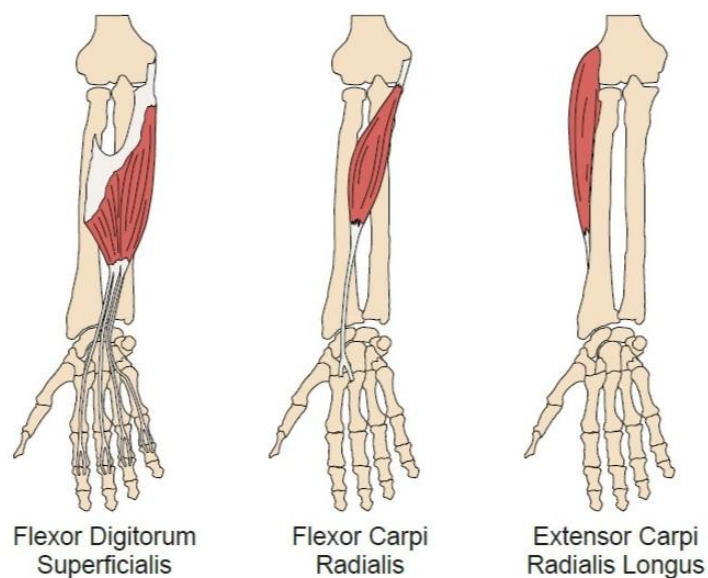
2.8 Colocación de sensores y preparación del sujeto

La colocación de los sensores se realizó siguiendo recomendaciones *SENIAM* para maximizar la relación señal-ruido mediante una adecuada localización sobre el vientre muscular y una orientación consistente respecto a la dirección de las fibras. En los casos requeridos, la piel se preparó mediante limpieza y ligera abrasión, especialmente cuando se utilizaron electrodos secos, con el fin de reducir la impedancia de contacto y mejorar la estabilidad de la señal.

Para la adquisición multicanal se emplearon tres sensores uMyo, identificados como Sensor 1, Sensor 2 y Sensor 3 con fines de trazabilidad experimental. El Sensor 1 se ubicó sobre el flexor carpo radial, identificado con el antebrazo en supinación, próximo al lado radial, mediante palpación del vientre muscular activado durante la flexión de muñeca y el cierre del puño. El Sensor 2 se posicionó sobre el flexor carpo ulnar, con la palma orientada hacia arriba, solicitando desviación ulnar combinada con flexión de muñeca para localizar el vientre muscular en el borde medial del antebrazo. El Sensor 3 se colocó sobre el extensor digitorum communis, con el antebrazo en pronación, identificando la zona de mayor activación en el dorso durante la extensión de los dedos.

Figura 2.4.

Músculos del antebrazo, sus relaciones anatómicas y la ubicación sugerida para cada uno de los sensores EMG.



Nota. Imagen reproducida de [36], © IEEE, 2025.

2.9 Configuración de adquisición y preprocesamiento de sEMG


El muestreo efectivo se fijó en 1 000 Hz. El preprocesamiento incluyó la eliminación de la componente de corriente continua, filtrado pasabanda entre 20 y 450 Hz, rectificación de la señal y filtrado paso bajo para la obtención de la envolvente, de acuerdo con prácticas clínicas y criterios de ingeniería de señales orientados a mejorar la separabilidad entre gestos y la robustez frente a ruido.

2.10 Selección de microcontrolador

El módulo NVIDIA Jetson Nano 2 GB se consideró como servidor alternativo para alojar la API de inferencia y el panel HMI, aprovechando soporte *JetPack* y aceleración GPU cuando se requieran redes más pesadas o visión para exergames. Las guías oficiales describen compatibilidad con *frameworks* de IA y despliegue *headless*. Sin embargo, por disponibilidad y simplicidad, se priorizó PC local para las primeras iteraciones, manteniendo compatibilidad binaria con Jetson. La adquisición BLE y reenvío vía USB se delegó a una ESP32-S3, como unidad de adquisición, que envía al servidor local las señales sEMG crudas. Esta separación permite aislar tiempos de radio de BLE y reducir carga en el microcontrolador. Se valoró que, si en fases futuras se migra a inferencia embebida, la ruta de cuantización a 8 bits en *Tensor Flow Lite Micro* y la disponibilidad de operadores permiten portar modelos CNN y LSTM mucho más simplificados.

Figura 2.5.

Placas de desarrollo ESP32 y Jetson Nano.



Nota. Elaboración propia a partir de imágenes de Espressif Systems y NVIDIA [37], [38], © IEEE, 2025.

2.11 Selección de fuente de alimentación

Para actuadores DYNAMIXEL se adoptó una fuente externa regulada dentro del rango permitido por XL330 y dimensionada en corriente para picos simultáneos de varios motores. Se empleó cables JST EHR-03 para la distribución del voltaje de alimentación para los motores, y se mantuvo alimentación lógica separada para servidor y ESP32. La elección de alimentación por red eléctrica, en lugar de baterías, se justifica por la naturaleza de banco fijo y por la reducción de masa y complejidad durante las pruebas. Se incluyó paro de emergencia cableado que corta la línea de potencia de actuadores, así como fusibles y protecciones frente a inversión de polaridad y sobrecorriente conforme a prácticas de seguridad en mecatrónica.

2.12 Selección del stack tecnológico

El frontend se implementó con Vite, *React 19*, *TypeScript* y *Tailwind CSS* para construir una HMI responsiva y modular, con dos vistas: paciente y clínico. El *backend* se implementó en Python con API REST basada en Flask, preprocesamiento con *SciPy* y ejecución del modelo en *TensorFlow Lite*. Esta combinación facilita la integración con bibliotecas de ciencia de datos, el despliegue local y la futura migración a TFL-Micro. Para persistencia se propuso *Firestore* para metadatos de sesión y *Firebase Storage* para ficheros CSV, aunque en la fase inicial se permitió almacenamiento local con sincronización posterior. Se adoptó *logging* estructurado, control de configuración por variables de entorno y CI/CD para pruebas automáticas del backend. Se definió un canal *WebSocket* opcional para *streaming* de métricas en tiempo real hacia el panel clínico, manteniendo la ruta principal de predicción por HTTP POST para robustez.

2.13 Proceso de Selección del método de IA y firmware

Se adoptó una arquitectura híbrida Convolutiva junto con LSTM por su capacidad de extraer características locales en tiempo y modelar dependencias secuenciales de sEMG, reportada con alto desempeño en la literatura reciente de reconocimiento de gestos mioeléctricos. Para despliegue se convirtió a TensorFlow Lite con cuantización post-entrenamiento, conservando un fallback de punto flotante para validaciones. Se establecieron dos currículos de entrenamiento inspirados en *Teacher-Led Condition* y *Learner-Led Condition*, el primero guía al usuario con ejemplos y re-entrena periódicamente con muestras verificadas por el clínico; el segundo incorpora ejemplos seleccionados por el propio usuario en tareas libres, equilibrando exploración y consolidación del modelo. La actualización del modelo se programó por bloques de sesión para mantener estabilidad en tiempo real. El firmware de ESP32 integró una librería BLE para uMyo, un buffer circular de 250 ms con 80 % de solape, envío de bursts por Wi-Fi a la API y temporización a 20 Hz de predicción, siguiendo el pipeline de la sección 2.2.

2.14 Recolección de datos

Se utilizaron sesiones guiadas con cuatro a ocho gestos y repeticiones por gesto. La aplicación de captura en Python (PySide6) automatizó instrucciones, contabilizó tiempos de activación/descanso y guardó CSV etiquetados. Se registró metadato de posición de electrodos conforme a SENIAM.

El preprocesamiento consistió en sustracción de media, filtro Butterworth 20–450 Hz, rectificación, paso bajo para envolvente y normalización Z-score por canal, replicando la práctica clínica y publicaciones de referencia. Se aplicó normalización temporal por interpolación para homogeneizar longitudes de ventanas. Se definió partición por sujeto para evitar sobreajuste a idiosincrasias musculares, y se aplicó validación cruzada estratificada.

2.15 Algoritmo de IA

La arquitectura CNN+LSTM incluyó capas Conv1D con *pooling*, seguidas de LSTM bidireccional y capa densa con *softmax*. Se empleó *data augmentation* específico para sEMG: ruido gaussiano de baja amplitud y deformación de magnitud. Se optimizó con AdamW y early stopping. Referencias recientes reportan desempeños comparables en sEMG para control de mano. Para despliegue se convirtió a TFLite con cuantización 8-bit de pesos y, cuando fue posible, cuantización consciente de entrenamiento, logrando menor latencia y tamaño de modelo sin degradación significativa.

2.16 Firmware y SDKs

El firmware se desarrolló en entorno Arduino para ESP32 con bibliotecas oficiales BLE y Wi-Fi, más cliente HTTP. Para XL330 se preparó control desde PC hacia la Jetson usando el SDK DYNAMIXEL, Python y C++, y U2D2, con *timeouts* y *retry* para garantizar robustez en bus TTL *half-duplex*.

2.17 Parámetros de diseño eléctrico

Se diseñó el esquema de alimentación con líneas separadas: potencia para actuadores DYNAMIXEL y lógica para servidor/ESP32. Se incluyeron fusibles, protección contra inversión y botón de paro que interrumpe potencia a motores. El retorno de referencia se manejó con estrella para minimizar bucles. El sistema de comunicación se estructuró en dos enlaces, conexión BLE desde el sensor uMyo hacia la ESP32 y Wi-Fi desde la ESP32 hacia la API local. Se definieron *heartbeats* y reconexión exponencial para pérdidas de enlace, con buffers en ESP32 que aseguran continuidad cuando la API tarda en responder. Se dispuso instrumentación para telemetría de corriente en actuadores y registro de temperatura en motores cuando el SDK lo permite, lo cual sirve como *biofeedback* de esfuerzo en tareas de agarre.

2.18 Componentes empleados

Tabla 2.4.

Listado de componentes empleados.

Subsistema	Componente	Función
Adquisición	uMyo werable EMG	EMG superficial, BLE
Adquisición	ESP32-S3	Gateway BLE-WiFi, buffer
Inferencia	PC local, Jetson Nano	API, preprocesamiento, TFLite
Actuación	Dynamixel XL330-M288-T	Actuadores, telemetría
Interfaz	U2D2, Power Hub Board	Interfaz USB-TTL, distribución de potencia
HMI	Frontend React y Tailwind	Panel clínico y vista paciente
Gemelo Virtual	Blender con rig articulado	Modelos y cinemática

2.19 Consideraciones éticas y legales

Se aseguró el cumplimiento de GDPR para protección de datos personales, incluyendo minimización, anonimización y portabilidad. Se obtuvo consentimiento informado conforme a los principios del Informe Belmont, protegiendo autonomía, beneficencia y justicia de los participantes. Se registraron protocolos para revisión por comité de ética institucional antes de iniciar sesiones con personas con amputación. Se adoptó gestión de riesgos inspirada en ISO 14971 para identificar peligros eléctricos, mecánicos y de software, y establecer controles como paro de emergencia, límites de corriente, topes mecánicos y pruebas previas sin carga. Para la HMI se tomaron referencias de diseño centrado en el humano según ISO 9241-210, priorizando comprensibilidad, retroalimentación inmediata y accesibilidad. La propiedad intelectual se gestionó mediante licencias de software compatibles, atribución de bibliotecas y resguardo de

resultados originales del proyecto, con vistas a potenciales registros de modelo de utilidad o software según evaluación institucional. o mioeléctrico

2.20 Estrategia de identificación

Para asegurar que los efectos observados corresponden a aprendizaje del usuario y mejora del modelo, se fijaron protocolos de control: sesiones con baseline inicial, pruebas repetidas en condiciones constantes, y evaluación con métricas objetivas de latencia, exactitud y tiempo de reacción. La actualización del modelo se realizó al final de cada sesión para evitar inestabilidad durante el ejercicio, comparando desempeño pre/post con pruebas no paramétricas. Se distinguió variabilidad intra-sujeto de inter-sujeto mediante diseño de particiones y almacenaje de metadatos de colocación de electrodos. Se planificó incorporar muestras de personas con muñón para mejorar la generalización del clasificador, conforme a recomendaciones de recopilación sEMG multi-sujeto.

Capítulo 3

3.1 Resultados de Adquisición de Datos sEMG

La campaña de adquisición se ejecutó mediante sesiones estructuradas con tres sensores uMyo ubicados sobre el antebrazo, registrando señales de electromiografía superficial durante bloques alternados de gesto y reposo. El protocolo operativo consideró la presentación de un tutorial breve antes de iniciar la secuencia de gestos; no obstante, se identificó que dicho tutorial generó registros que fueron etiquetados erróneamente como un gesto válido, Esférico, por lo que debió ser tratado como un segmento inválido durante el preprocesamiento. Adicionalmente, se observaron eventos típicos de adquisición en señales sEMG en escenarios reales:

1. Valores perdidos, NaN, asociados a errores de registro o transmisión.
2. Valores exactamente cero vinculados a desconexión o pérdida momentánea de señal.
3. Variaciones de duración por gesto que sugieren transiciones no instantáneas y posible contaminación entre bloques adyacentes.

Estas condiciones motivaron la aplicación de un proceso sistemático de depuración, segmentación y normalización, descrito en las secciones siguientes.

Tabla 3.1.

Protocolo de sesión empleado para la adquisición sEMG.

Elemento	Descripción
Sensores	3 uMyo sEMG
Estructura base	Bloques alternados de gesto y reposo
Duración nominal por gesto	5 s
Duración nominal de reposo	5 s
Gestos planificados	Abrir, Cerrar, Like, Apuntar, Pinza, Cilíndrico, Esférico
Circuitos por voluntario	2 - secuencia completa
Observación crítica	Tutorial previo generó datos etiquetados erróneamente como Esférico

3.2 Construcción del Dataset y Depuración

El procesamiento inició con la identificación automática de archivos de sesión almacenados en el directorio de sesiones, registrándose 173 archivos CSV. Posteriormente, se consolidó el *dataset* mediante lectura robusto, con soporte de *encoding* para caracteres especiales,

homogeneización del nombre de la columna de etiqueta y detección dinámica de los tres canales EMG. A continuación, se aplicaron filtros de depuración con el objetivo de excluir registros no representativos del gesto real o corruptos:

- Eliminación de valores nulos, NaN, en los canales EMG.
- Eliminación de filas con valores EMG = 0 en cualquier canal, como indicador de desconexión o fallo de captura.
- Normalización de etiquetas con errores de codificación, agrupando variantes bajo la etiqueta correcta.
- Eliminación del primer bloque de “Esférico” por sesión, interpretado como el segmento del tutorial mal etiquetado.
- Separación de registros de diagnóstico en un conjunto excluido, por no corresponder a gestos de entrenamiento.

Como resultado, se obtuvieron las siguientes magnitudes globales: 322 333 registros cargados, 3 140 registros excluidos y 319 193 registros válidos para análisis y modelado.

Tabla 3.2.

Resumen cuantitativo de depuración del dataset.

Métrica	Valor
Archivos de sesión detectados	173
Registros cargados	322 333
Registros excluidos	3 140
Registros válidos para análisis	319 193
Canales utilizados	emg1, emg2, emg3
Acción correctiva clave	Eliminación del 1er bloque Esférico por sesión tutorial

3.3 Consistencia temporal y segmentación por bloques

Para evaluar la consistencia de la recolección, se segmentaron las señales en bloques continuos de una misma etiqueta. Se definió un identificador de bloque global, *global_block_id*, que incrementa cada vez que ocurre un cambio de etiqueta o cambia el archivo de origen. Este criterio evita mezclar transiciones entre sesiones distintas y permite cuantificar la duración real de cada instancia de gesto. La Tabla 3.3 resume las estadísticas de duración por gesto, se evidencian

valores mínimos muy bajos y máximos elevados en algunos gestos. Estas observaciones son coherentes con transiciones no sincronizadas entre el cambio de gesto en la interfaz y el inicio del esfuerzo muscular real, y posibles intervalos prolongados de etiquetados como un mismo gesto por el retraso en la interacción del voluntario o del operador.

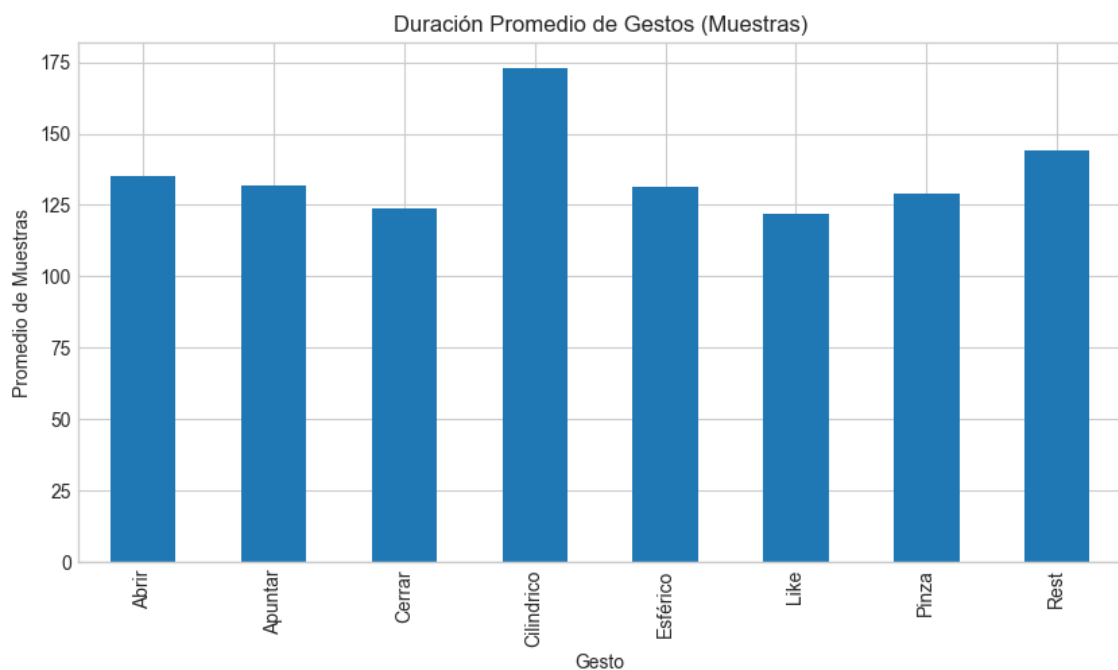
Tabla 3.3.

Estadísticas de duración en número de muestras por gesto.

Gesto	Mín	Máx	Promedio	Cant. instancias
Abrir	4	886	134.91	176
Apuntar	1	1 735	131.62	171
Cerrar	1	247	123.85	172
Cilíndrico	2	4 755	173.13	172
Esférico	4	157	131.56	153
Like	1	156	121.88	170
Pinza	4	157	129.22	172
Rest	1	2 586	144.22	1 101

Figura 3.3.

Duración promedio de gestos por etiqueta.



Nota. Elaboración propia, © IEEE, 2025.

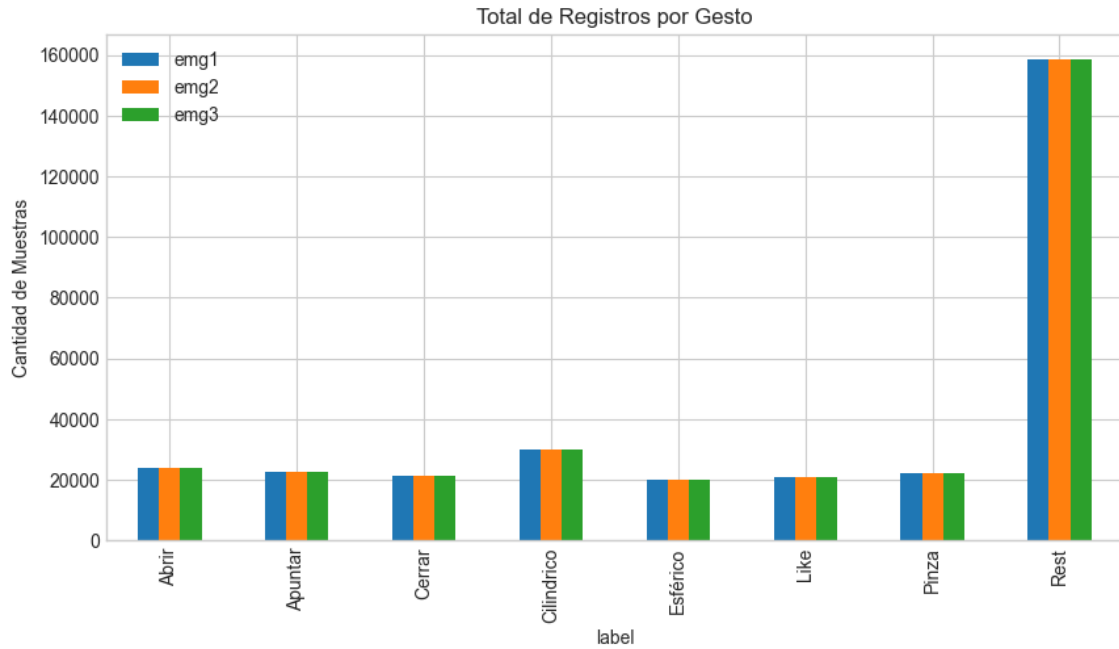
3.4 Distribución del dataset y desbalance de clases

Posterior a la depuración, se cuantificó el número total de muestras por etiqueta. El conjunto presenta un desbalance marcado hacia la clase Rest, que concentra 158 786 muestras, mientras que los gestos activos presentan entre 20 000 y 30 000 muestras cada uno. Este desbalance es relevante porque puede inducir sesgos durante el entrenamiento supervisado, un clasificador puede alcanzar métricas globales altas priorizando la clase mayoritaria, mientras mantiene dificultades en clases minoritarias o con menor número de instancias efectivas.

Tabla 3.4.

Conteo total de muestras por etiqueta.

Etiqueta	Registros
Abrir	23 745
Apuntar	22 507
Cerrar	21 303
Cilíndrico	29 779
Esférico	20 128
Like	20 720
Pinza	22 225
Rest	158 786

Figura 3.4.*Total de registros por gesto.**Nota.* Elaboración propia, © IEEE, 2025.

3.5 Normalización de señales

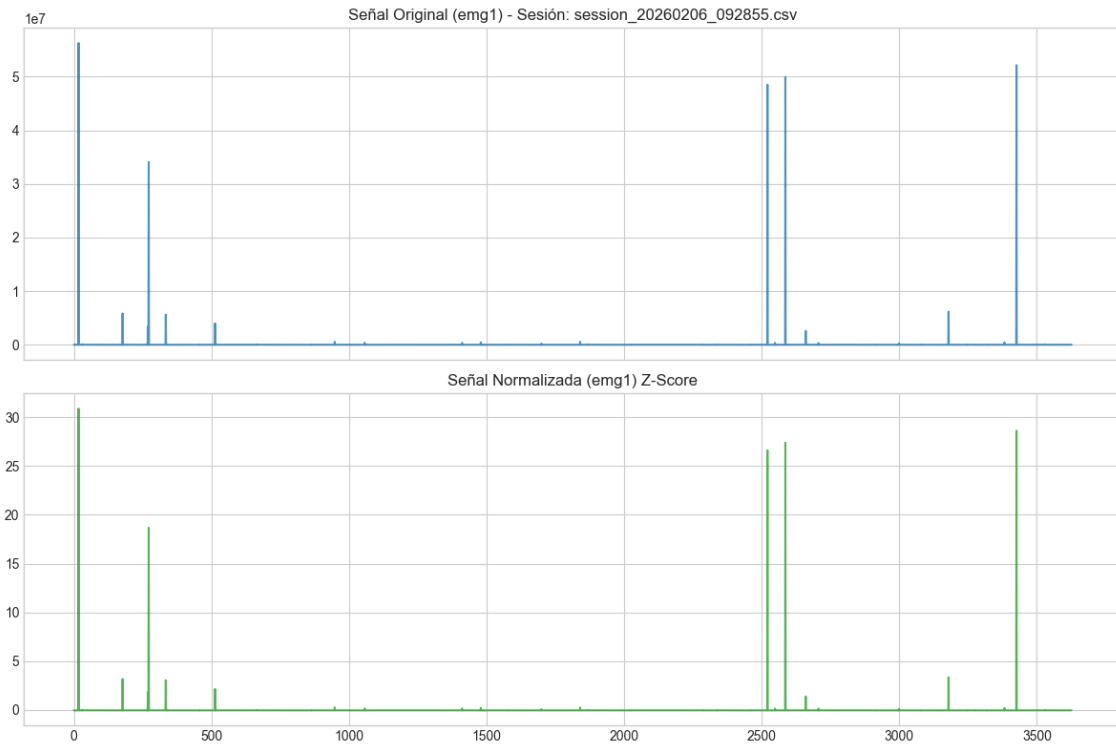
Con el objetivo de reducir la variabilidad entre sesiones y participantes, se aplicó normalización Z-Score por sesión y por canal EMG. Este enfoque estandariza cada canal respecto a la media y desviación estándar de la sesión, disminuyendo la influencia de escalas absolutas de amplitud y facilitando el aprendizaje de patrones relativos.

$$x_{norm} = \frac{x - \mu}{\sigma + \varepsilon} \quad (2.1)$$

donde x es la muestra original, μ es la media del canal en la sesión, σ es la desviación estándar del canal en la sesión y ε es un término pequeño para evitar división por cero. Para ilustrar el efecto, se comparó la señal original versus la señal normalizada de un canal representativo (emg1) en una sesión de ejemplo.

Figura 3.5.

Señal original vs. señal normalizada del canal emg1 en una sesión representativa.



Nota. Elaboración propia, © IEEE, 2025.

3.6 Generación de Ventanas para Aprendizaje Supervisado

Para el entrenamiento del modelo se empleó una estrategia de ventaneo deslizante sobre bloques continuos de etiqueta. Se definieron los parámetros:

- Tamaño de ventana: $W = 157$ muestras
- Desplazamiento: $S = 5$ muestras

Cada ventana contiene una matriz $W \times C$, donde $C=3$ corresponde a los canales emg1, emg2 y emg3 normalizados.

$$N = \left\lfloor \frac{L-W}{S} \right\rfloor \text{ para } L > W \quad (2.1)$$

donde L es la longitud del bloque en muestras.

La implementación de ventanas aplicó un rango del tipo $range(0, L - W, S)$. En consecuencia, si $L=W$, entonces $L-W=0$ y no se genera ninguna ventana. Esto explica por qué aun existiendo muestras de Like, Pinza y Esférico en el dataset, dichas clases pueden desaparecer del conjunto de entrenamiento si sus bloques tienen longitudes máximas cercanas a 156 muestras. De

hecho, la estadística muestra máximos de 156 para Like y 157 para Pinza y Esférico, lo cual reduce drásticamente la generación efectiva de ventanas para estas etiquetas. Como resultado, el conjunto final de entrenamiento quedó con X de dimensión (6311, 157, 3) y etiquetas Y asociadas, con cinco clases efectivas: Abrir, Apuntar, Cerrar, Cilíndrico y Rest.

Tabla 3.5.

Parámetros de ventaneo utilizados para el modelado.

Parámetro	Símbolo	Valor
Tamaño de ventana	W	157 muestras
Desplazamiento	S	5 muestras
Canales	C	3
Forma de entrada		157, 3

3.7 Entrenamiento del modelo CNN

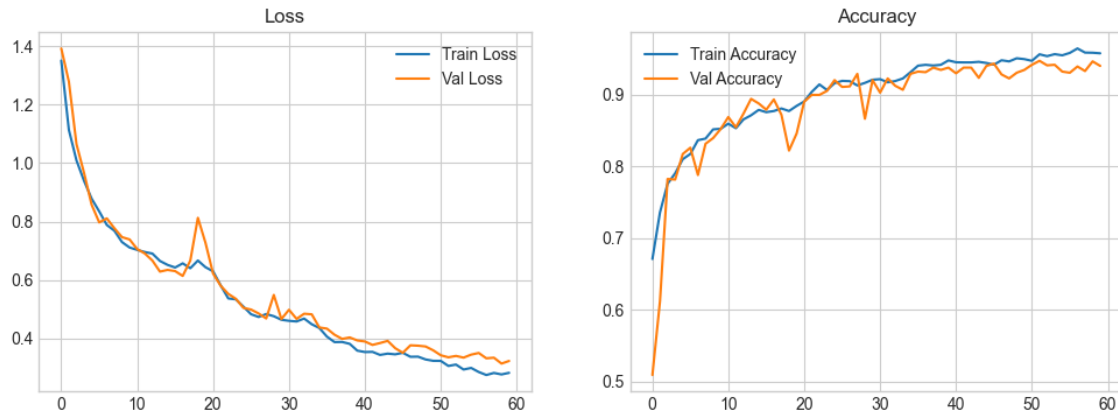
Se entrenó una red neuronal convolucional unidimensional con entrada 157,3 compuesta por dos bloques convolucionales con normalización por lotes, activación ReLU, reducción por MaxPooling y regularización mediante Dropout y penalización L2. Posteriormente, se emplearon capas densas para clasificación multiclase con función de salida Softmax. El entrenamiento se realizó con optimizador Adam y función de pérdida categorical crossentropy. Para mejorar la generalización y estabilidad se aplicaron callbacks:

- **Early Stopping:** detención temprana.
- **Reduce LR On Plateau:** reducción automática de tasa de aprendizaje ante estancamiento de la pérdida de validación.

El proceso se ejecutó hasta 60 épocas, observándose convergencia estable de la pérdida y mejora progresiva de la precisión.

Figura 3.7.

Curvas de entrenamiento: Pérdida, Loss, y Precisión, Accuracy, para entrenamiento y validación.



Nota. Elaboración propia, © IEEE, 2025.

3.8 Evaluación cuantitativa del clasificador

El desempeño se evaluó en un conjunto de prueba mediante precisión, exhaustividad, F1-score por clase y métricas globales. El modelo alcanzó un accuracy global aproximado a 0.95 y un F1-score ponderado de aproximadamente 0.9449, lo cual indica una clasificación consistente en clases dominantes. Sin embargo, se identificó un comportamiento no homogéneo entre clases. En particular, la clase del gesto Cerrar obtuvo un recall bajo, de aproximadamente 0.14, pese a mostrar precisión alta. Este patrón es consistente con un soporte reducido, muy pocos ejemplos de prueba, lo que limita la estimación estable de métricas y sugiere insuficiencia de ventanas efectivas para dicha clase. Asimismo, el desbalance hacia el gesto Rest contribuye a que la métrica global se mantenga alta incluso si clases minoritarias presentan degradación.

Tabla 3.7.

Métricas por clase.


Clase	Precision	Recall	F1-score	Support
Abrir	0.91	0.91	0.91	43
Apuntar	0.90	1.00	0.95	54
Cerrar	1.00	0.14	0.25	7
Cilíndrico	0.88	0.95	0.92	303

Rest	0.98	0.95	0.96	856
Global ponderado	—	—	0.9449	1263

La matriz de confusión complementa el análisis mostrando que Rest y Cilíndrico concentran la mayoría de las predicciones correctas, mientras que Cerrar tiende a confundirse con clases de mayor frecuencia o con patrones musculares similares.

Figura 3.8.

Matriz de confusión del clasificador CNN-ID.



Nota. Elaboración propia, © IEEE, 2025.

3.9 Discusión: implicaciones para el sistema Dyna-Train

Los resultados confirman que el pipeline propuesto permite entrenar un clasificador funcional con desempeño global alto en condiciones reales. No obstante, el análisis revela factores críticos que deben ajustarse para garantizar consistencia clínica y operación robusta:

- **Segmentación y contaminación entre reposo y gesto:** La variabilidad extrema en duraciones sugiere transiciones no controladas, esto puede mezclar la actividad muscular residual del gesto anterior dentro del reposo y viceversa, afectando la pureza de las ventanas de entrenamiento.
- **Desbalance de clases:** La clase Rest domina el dataset, lo cual puede sesgar el modelo hacia predicciones conservadoras.
- **Pérdida de clases por configuración de ventaneo:** El tamaño de ventana $W=157$ y la condición de generación, solo si $L>W$, eliminan por defecto gestos con segmentos cortos o cercanos al umbral. Este hallazgo explica que el entrenamiento efectivo haya operado con 5 clases, aunque el protocolo contemple 7 gestos.

En términos de integración con el banco de entrenamiento, estos puntos impactan directamente la experiencia del usuario, la clasificación debe ser estable y rápida, pero también representativa de todos los gestos de interés. Por ello, la siguiente iteración del sistema debe priorizar una segmentación más robusta, con buffers, y asegurar instancias suficientes por clase.

3.10 Limitaciones y mejoras inmediatas recomendadas

A partir del análisis, se establecen mejoras concretas, priorizadas por impacto:

A. Correcciones del dataset y etiquetado.

- Etiquetar el tutorial como INVÁLIDO desde captura o excluirlo por regla explícita.
- Estandarizar el inicio y fin del gesto con un marcador operacional, cuenta regresiva y confirmación visual y sonora.

B. Correcciones de segmentación.

- Introducir un buffer de seguridad entre bloques, descartar los primeros y últimos b ms por muestras de cada bloque para reducir contaminación.
- Evaluar segmentación por energía/envolvente para detectar inicio real de contracción.

C. Correcciones del ventaneo.

- Cambiar la condición de ventanas a $range(0, L - W + 1, S)$ para incluir bloques con $L=W$.
- Ajustar W a un tamaño menor si los bloques reales son cortos.
- Balancear ventanas por clase o usar ponderación de clases durante entrenamiento.

D. Evaluación más rigurosa.

- Separación de entrenamiento y prueba por voluntario para medir generalización real.
- Incrementar instancias de clases problemáticas para estabilizar métricas.

En este capítulo se presentaron los resultados de adquisición, depuración y modelado de señales sEMG empleando tres sensores uMyo, así como la evaluación cuantitativa de un clasificador basado en CNN-1D entrenado mediante ventaneo deslizante. La consolidación del dataset evidenció condiciones inherentes a un entorno real de captura, valores nulos, tramos en cero, variabilidad de duración por gesto y segmentos de tutorial incorrectamente etiquetados, las cuales fueron mitigadas mediante reglas de limpieza y normalización de etiquetas, exclusión de diagnósticos y estandarización Z-Score por sesión. Posteriormente, la segmentación por bloques continuos y el esquema de ventanas permitieron construir un conjunto de entrenamiento consistente, obteniendo un desempeño global alto en el conjunto de prueba y una matriz de confusión que describe los patrones de acierto y error por clase.

No obstante, el análisis también reveló limitaciones operativas y metodológicas relevantes, desbalance marcado hacia la clase Rest, pérdida efectiva de clases al generar ventanas cuando los bloques no superan el tamaño definido, y evidencia de las transiciones de gesto a reposo susceptibles de contaminar ventanas adyacentes. Estas observaciones son críticas porque afectan tanto la robustez del modelo como la experiencia de entrenamiento del usuario, particularmente cuando el sistema se despliega como herramienta de práctica guiada con retroalimentación inmediata. Con base en lo anterior, el Capítulo 4 sintetiza las conclusiones del trabajo, discute su contribución técnica y aplicada, y establece recomendaciones concretas para la siguiente iteración del sistema Dyna-Train, con énfasis en estandarización clínica, mejora del pipeline de segmentación, sincronización en tiempo real y validación comparativa en escenarios de uso.

Capítulo 4

4.1 Conclusiones y recomendaciones

4.1.1 Conclusiones

- Se implementó un banco de entrenamiento físico digital que permite práctica guiada del control mioeléctrico previo a la entrega de la prótesis, integrando adquisición sEMG, ejecución en mano robótica, gemelo virtual e interfaz web orientada a entrenamiento y seguimiento.
- Los perfiles protésicos dinámicos demostraron ser una estrategia efectiva para emular configuraciones con diferentes grados de libertad, incorporando de límites articulares, bloqueos y reglas de ejecución por grupos, lo que facilita la adaptación del sistema a múltiples prótesis objetivo sin rediseño completo.
- La cadena de ejecución del sistema habilitó una arquitectura de adquisición y procesamiento local para entrenamiento e inferencia, favoreciendo una operación autónoma en entornos clínicos o de laboratorio, con enfoque en baja latencia y continuidad de servicio sin dependencia de conectividad externa.
- El pipeline de datos y el modelado con CNN-1D permitió entrenar un clasificador funcional a partir de registros reales, pero el análisis evidenció factores críticos que condicionan la generalización. Estos hallazgos sustentan la necesidad de fortalecer la segmentación y el diseño del dataset para cubrir la totalidad de gestos objetivo con instancias suficientes.
- El registro de métricas y la incorporación de lógicas TLC y LLC constituyen una base para retroalimentación objetiva y adaptación progresiva durante las sesiones, con una validación clínica posterior.

4.1.2 Recomendaciones

- Estandarizar la colocación del sistema sEMG y registrar metadatos para reducir variabilidad entre sesión y mejorar la comparabilidad entre participantes.
- Robustecer la segmentación entre gesto y reposo incorporando buffers de descarte al inicio y fin de cada bloque, detección de activación basada en energía y envolvente, y marcadores operativos para sincronizar el inicio real del esfuerzo muscular con el etiquetado.

- Ajustar la estrategia de ventaneo para evitar pérdida de clases: emplear una condición que incluya $L=W$, evaluar tamaños de ventana acordes a la duración real de los bloques y aplicar balance por clase para mitigar el sesgo hacia el gesto Rest.
- Implementar sincronización en tiempo real entre backend, frontend y gemelo virtual mediante WebSocket, con un esquema de timestamps y confirmación de estado para asegurar consistencia entre inferencia, animación y actuación física.
- Definir un conjunto mínimo de métricas clínicas y de desempeño, incluyendo indicadores por clase, métricas de sesión y métricas de adherencia, para habilitar interpretación en rehabilitación.
- Realizar estudios piloto con separación por sujeto, protocolos repetibles y comparación con líneas base, incluyendo reportes de latencia y estabilidad del sistema.

Referencias


- [1] E. A. Biddiss and T. T. Chau, “*Upper limb prosthesis use and abandonment: A survey of the last 25 years,*” *Prosthetics and Orthotics International*, vol. 31, no. 3, pp. 236–257, Sep. 2007. [Online]. Disponible en: <https://doi.org/10.1080/03093640600994581>
- [2] E. Scheme y K. Englehart, “*Electromyogram pattern recognition for control of powered upper-limb prostheses: State of the art and challenges for clinical use,*” *JRRD*, vol. 48, no. 6, pp. 643–659, 2011. [Online]. Disponible en: <https://www.proquest.com/scholarly-journals/electromyogram-pattern-recognition-control/docview/879503989/se-2>
- [3] N. Parajuli et al., “*Real-Time EMG Based Pattern Recognition Control for Hand Prostheses*” *Sensors*, 19(20):4596, 2019. [Online]. Disponible en: <https://doi.org/10.3390/s19204596>
- [4] Y. X. Teh et al., “*Understanding limb position and external load effects on EMG-PR,*” *J. NeuroEng. Rehabil.*, 17:41, 2020. [Online]. Disponible en: <https://doi.org/10.1186/s12984-020-00683-6>
- [5] L. Hargrove, K. Englehart y B. Hudgins, “*The effect of electrode displacements,*” *Biomed. Signal Process. Control*, 3(2), pp. 175–180, 2008. [Online]. Disponible en: <https://doi.org/10.1016/j.bspc.2007.11.005>
- [6] R. N. Khushaba et al., “*Towards limb position invariant myoelectric PR...,*” *Neural Networks*, 55, pp. 52–58, 2014. [Online]. Disponible en: <https://doi.org/10.1016/j.neunet.2014.03.010>
- [7] A. Phinyomark et al., “*EMG Pattern Recognition in the Era of Big Data and DL,*” *Informatics*, 2(3):21, 2018. [Online]. Disponible en: <https://doi.org/10.3390/informatics2030021>
- [8] U. Côté-Allard et al., “*Deep Learning for EMG Hand Gesture... using Transfer Learning,*” *IEEE Trans. Neural Syst. Rehabil. Eng.*, 27(4), pp. 760–771, 2019. [Online]. Disponible en: <https://doi.org/10.1109/TNSRE.2019.2896269>
- [9] M. Atzori, A. Gijssberts, C. Castellini et al., “*Electromyography data for non-invasive naturally-controlled robotic hand prostheses,*” *Sci. Data*, 1:140053, 2014. [Online]. Disponible en: <https://doi.org/10.1038/sdata.2014.53>

- [10] M. Atzori et al., “Characterization of a benchmark database for myoelectric movement classification,” *IEEE TNSRE*, 23(1), pp. 73–83, 2015. [Online]. Disponible en: <https://doi.org/10.1109/TNSRE.2014.2328495>
- [11] J. Farrell y R. F. Weir, “The optimal controller delay for myoelectric prostheses,” *IEEE TNSRE*, 15(1), pp. 111–118, 2007. [Online]. Disponible en: <https://doi.org/10.1109/TNSRE.2007.891391>
- [12] J. Tosi et al., “Performance Evaluation of Bluetooth Low Energy,” *Sensors*, 17(12):2898, 2017. [Online]. Disponible en: <https://doi.org/10.3390/s17122898>
- [13] M. Spörk et al., “Improving the Timeliness of BLE in Noisy Environments,” *ACM TIoT*, 1(1):111, 2019. [Online]. Disponible en: <https://doi.org/10.1145/3377366>
- [14] A. M. Dollar y L. U. Odhner, “The iHY Hand: A Compliant, Underactuated Hand...,” *Int. J. Robot. Res.*, 33(5), pp. 736–752, 2014. [Online]. Disponible en: <https://doi.org/10.1177/0278364913514466>
- [15] R. Deimel y O. Brock, “A Novel Type of Compliant, Underactuated Robotic Hand,” *Robotics: Science and Systems*, 2015/2016. [Online]. Disponible en: <https://doi.org/10.1177/0278364915592961>
- [16] C. Piazza, M. G. Catalano, A. Bicchi, “A Century of Robotic Hands,” *Annu. Rev. Control Robot. Auton. Syst.*, 2, pp. 1–32, 2019. [Online]. Disponible en: <https://doi.org/10.1146/annurev-control-060117-105003>
- [17] I. Llop-Harillo et al., “Grasping Ability and Motion Synergies in Affordable Tendon-Driven Hands,” *Front. Neurorobot.*, 14:57, 2020. [Online]. Disponible en: <https://doi.org/10.3389/fnbot.2020.00057>
- [18] uDevices, “uMyo – wearable EMG sensor,” uDevices online store, 2025. [Online]. Disponible: https://udevices.io/products/umyo-wearable-emg-sensor?srsltid=AfmBOooOtjXI90vImCLU7jCBJhTdIRZLWLEY49Afe_qPfnV0uaQ3FLEP.
- [19] W. Li et al., “Current status and clinical perspectives of extended reality for upper-limb amputees,” *Front. Bioeng. Biotechnol.*, 11:1334771, 2024. [Online]. Disponible en: <https://doi.org/10.3389/fbioe.2023.1334771>

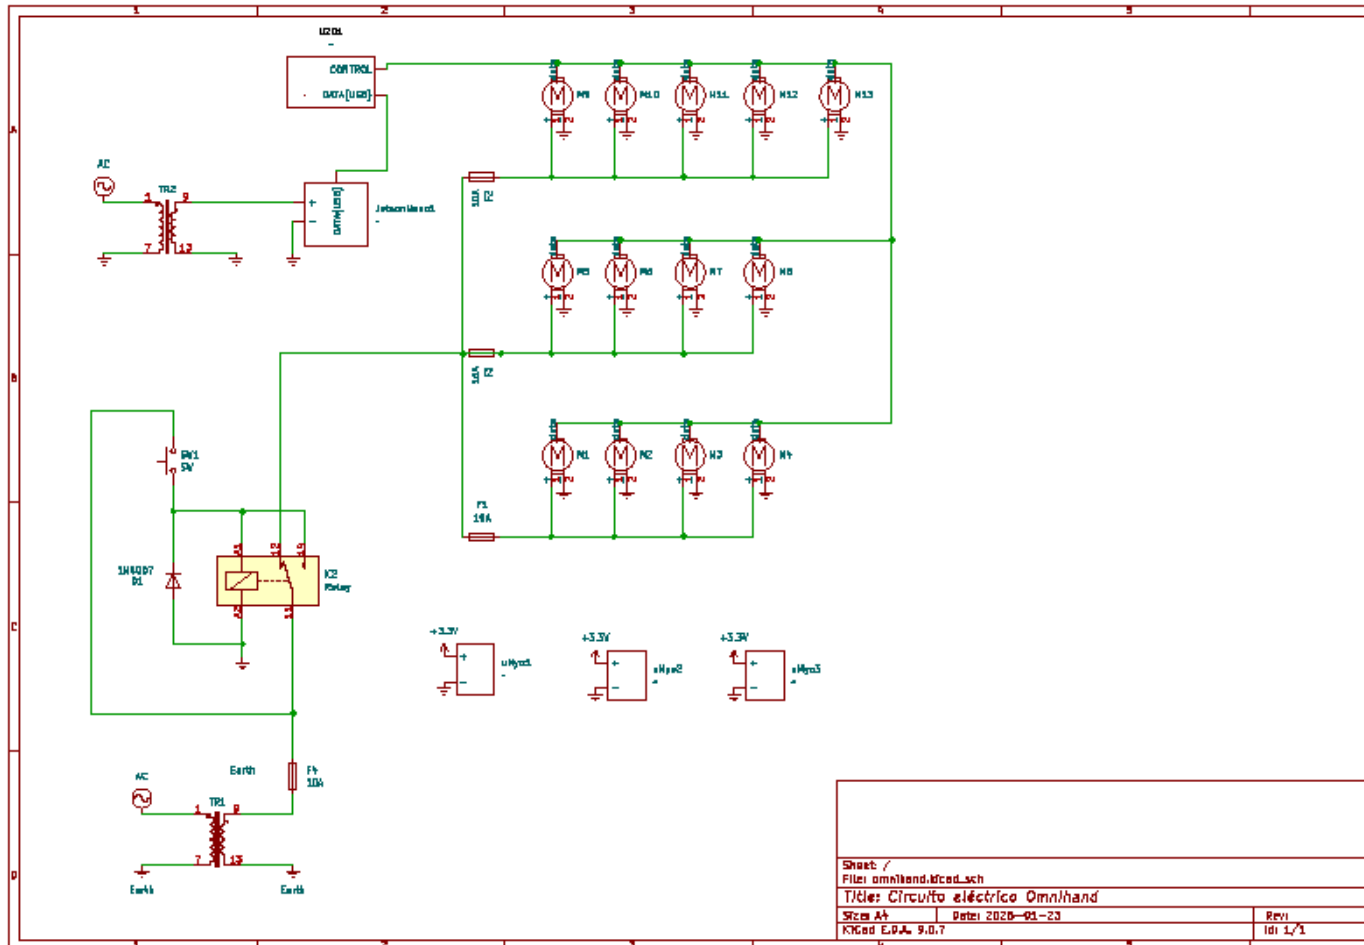
- [20] K. Shaw, A. Agarwal, y D. Pathak, “LEAP Hand: Low-Cost, Efficient, and Anthropomorphic Hand for Robot Learning,” póster, 2021. [Online]. Disponible: https://v1.leaphand.com/static/leap_hand_poster.pdf.
- [21] R. M. Carro et al., “Serious Games for Training Myoelectric Prostheses...,” *Children*, 9(3):423, 2022. [Online]. Disponible en: <https://doi.org/10.3390/children9030423>
- [22] K. Guo, J. Lu, Y. Wu, X. Hu and H. Yang, “The Latest Research Progress on Bionic Artificial Hands: A Systematic Review,” *Micromachines*, vol. 15, no. 7, p. 891, Jul. 2024. [Online]. Disponible en: <https://doi.org/10.3390/mi15070891>
- [23] G. Koulouras et al., “Evolution of Bluetooth Technology: BLE in the IoT Ecosystem,” *Sensors*, 25(4):996, 2025. [Online]. Disponible en: <https://doi.org/10.3390/s25040996>.
- [24] Z. Zhang et al., “Electromyographic hand gesture recognition using multi-attention DL,” *Biomed. Signal Process. Control*, 93:106086, 2024. [Online]. Disponible en: <https://doi.org/10.1016/j.bspc.2023.106086>
- [25] U. Côté-Allard et al., “Interpreting DL Features for Myoelectric Control,” arXiv:1912.00283, 2019. [Online]. Disponible en: <https://arxiv.org/abs/1912.00283>
- [26] S. Antfolk et al., “Artificial redirection of sensation feedback in upper-limb prostheses: a review,” *Neurorehabil. Neural Repair*, 27(8), pp. 673–683, 2013. [Online]. Disponible en: <https://doi.org/10.1177/1545968313481288>
- [27] T. A. Kuiken, G. Li, B. A. Lock, R. D. Lipschutz, L. A. Miller, K. A. Stubblefield, and K. B. Englehart, “Targeted muscle reinnervation for real-time myoelectric control of multifunction artificial arms,” *J. Am. Med. Assoc.*, vol. 301, no. 6, pp. 619-628, Feb. 2009. [Online]. Disponible en: <https://doi.org/10.1001/jama.2009.116>
- [28] B. Hudgins, P. Parker y R. Scott, “A new strategy for multifunction myoelectric control,” *IEEE Trans. Biomed. Eng.*, 1993. [Online]. Disponible en: <https://doi.org/10.1109/10.204774>
- [29] M. Atzori y H. Müller, “Electromyography data for non-invasive naturally-controlled robotic hand prostheses,” *Sci. Data*, 2014. [Online]. Disponible en: <https://doi.org/10.1038/sdata.2014.53>

- [30] M. Atzori *et al.*, “Characterization of a benchmark database for myoelectric movement classification,” *IEEE TNSRE*, 2015. [Online]. Disponible en: <https://doi.org/10.1109/TNSRE.2014.2328495>
- [31] L. Hargrove, K. Englehart y B. Hudgins, “*A training strategy to reduce classification degradation due to electrode displacements*,” *IEEE TNSRE*, 2008. [Online]. Disponible en: <https://doi.org/10.1016/j.bspc.2007.11.005>
- [32] ISO 9241-210:2010(E), “*Ergonomics of human–system interaction — Part 210: Human-centred design for interactive systems*,” International Organization for Standardization, Geneva, Switzerland, Mar. 15, 2010. [Online]. Disponible en: <https://www.alekvs.com/wp-content/uploads/2025/06/iso-9241-210.pdf>
- [33] Reglamento General a la Ley Orgánica de Protección de Datos Personales, Decreto Ejecutivo No. 904, Registro Oficial Suplemento No. 435, Ecuador, 13-Nov-2023. Disponible en: https://www.cosede.gob.ec/wp-content/uploads/2023/12/REGLAMENTO-GENERAL-A-LA-LEY-ORG%C3%81NICA-DE-PROTECCION-DE-DATOS-PERSONALES_compressed-1.pdf
- [34] National Commission for the Protection of Human Subjects of Biomedical and Behavioral Research, *Ethical Principles and Guidelines for the Protection of Human Subjects of Research (The Belmont Report)*, U.S. Department of Health, Education, and Welfare, Washington, DC, 1978. [Online]. Disponible en: <https://www.bioeticayderecho.ub.edu/archivos/norm/InformeBelmont.pdf>
- [35] A. Buryanov y V. Kotiuk, “*Proportions of Hand Segments*,” *Int. J. Morphol.*, vol. 28, no. 3, pp. 755–758, 2010. [Online]. Disponible en: <https://scielo.conicyt.cl/pdf/ijmorphol/v28n3/art15.pdf>
- [36] Delsys Inc., Technical Note 101: EMG Sensor Placement, Boston, MA, EE. UU., Technical Note 101, Delsys Inc., 2014. [Online]. Disponible en: <https://delsys.com/downloads/TECHNICALNOTE/101-emg-sensor-placement.pdf>
- [37] NVIDIA Corporation, Getting Started with Jetson Nano 2GB Developer Kit. [Online]. Disponible en: <https://developer.nvidia.com/embedded/learn/get-started-jetson-nano-2gb-devkit>
- [38] Espressif Systems, ESP32 Wi-Fi & Bluetooth SoC. [Online]. Disponible en: <https://www.espressif.com/en/products/socs/esp32>

Apéndice A
 Planos mecánicos y eléctrico




Plano 1




Sheet /		Date: 2020-03-23	
File: omihand.kicad_sch		Rev: 1/1	
Title: Circuito eléctrico Omihand		Id: 1/1	
Sheet: 1/1	Date: 2020-03-23	Rev: 1/1	
Kicad E.D.A. 9.0.7			


Plano 2








Plano 3



Plano 4




Plano 5




				TOLERANCIA:	PESO: 0,020 kg	MATERIALES: PLA - 3D Printing	
				FECHA	NOMBRE	DENOMINACIÓN: MCP-I	ESCALA: 1 : 1
				DES.			
				REV.			
				APRO.		NÚMERO DE DIBUJO: 1	
EDICIÓN	MODIFICACIÓN	FECHA	NOMBRE	FIRMA:			


Plano 6




Plano 7




Plano 8




Plano 9




Plano 10




Plano 11




Plano 12




Plano 13




Plano 14



Plano 15



Plano 16



Plano 17