



**Universidad Abierta
Interamericana**

Facultad de Tecnología Informática

**Aplicación de Deep Learning Federado para el Control
Personalizado de Prótesis Mioeléctricas**

Profesora de Trabajo Final: Dra. Marcela Samela

Alumna: Bárbara Daniela Lobosco

Trabajo Final de Carrera presentado para obtener el título de
Licenciatura en Gestión de Tecnología Informática

Julio, 2026

Resumen

El presente estudio se realiza con el objetivo de explorar una solución que permita interpretar señales electromiográficas (EMG) con mayor exactitud en prótesis mioeléctricas, manteniendo al mismo tiempo la privacidad de los datos del usuario.

Para ello, se estructura una metodología basada en tres pilares de evidencia: una revisión exhaustiva del estado del arte sobre redes neuronales profundas y aprendizaje federado, una encuesta cuantitativa a profesionales y una entrevista cualitativa a un especialista en inteligencia artificial y ciberseguridad.

El análisis de los datos permite validar de manera contundente la hipótesis de investigación. Teóricamente, se comprueba que los modelos profundos superan a los convencionales, logrando tasas de cumplimiento de movimientos de hasta el 94,4%, mientras que los resultados de los enfoques federados respaldan un riesgo nulo de exposición de datos.

Cuantitativamente, el 86,5% de los expertos encuestados afirma que el Aprendizaje Profundo mejora la personalización y el 62,2% valida al Aprendizaje Federado como el mecanismo idóneo para resguardar la información biomédica. Finalmente, desde el enfoque cualitativo, se identifican arquitecturas híbridas y árboles de decisión locales como las soluciones técnicas necesarias para superar los actuales cuellos de botella de *hardware*.

A través de este trabajo, se establecen los criterios técnicos y éticos que demuestran que la combinación de estas tecnologías es viable para desarrollar prótesis de próxima generación, logrando conciliar la máxima precisión funcional con un estricto compromiso ético sobre la privacidad de los datos del usuario.

Palabras clave: extremidades artificiales, inteligencia artificial, interfaces de usuario, redes neuronales, señales, sistemas de control de aprendizaje

Abstract

This study aims to explore a solution that allows for more accurate interpretation of electromyographic (EMG) signals in myoelectric prostheses, while maintaining user data privacy.

To this end, a methodology based on three pillars of evidence is structured: a comprehensive review of the state of the art on deep neural networks and federated learning, a quantitative survey of professionals, and a qualitative interview with an artificial intelligence and cybersecurity specialist.

The data analysis provides compelling validation of the research hypothesis. Theoretically, it is confirmed that deep models outperform conventional ones, achieving movement accuracy rates of up to 94.4%, while the results of the federated approaches support a zero risk of data exposure.

Quantitatively, 86.5% of the surveyed experts affirm that Deep Learning improves personalization, and 62.2% validate Federated Learning as the ideal mechanism for safeguarding biomedical information. Finally, from a qualitative perspective, hybrid architectures and local decision trees are identified as the necessary technical solutions to overcome current hardware bottlenecks.

This work establishes the technical and ethical criteria that demonstrate that combining these technologies is viable for developing next-generation prostheses, achieving maximum functional precision with a strict ethical commitment to user data privacy.

Keywords: artificial intelligence, artificial limbs, learning control systems, neural networks, signals, user interfaces

Dedicatoria

A mi esposo, por su amor, paciencia y por acompañarme incondicionalmente en cada paso de este camino. Gracias por ser mi sostén en los momentos de mayor esfuerzo y por alentarme a seguir, incluso cuando dudaba de mí.

A mis padres, por ser el ejemplo de esfuerzo y perseverancia que siempre me inspiró. Por enseñarme el valor del estudio, por confiar en mis decisiones y por estar presentes con su apoyo incondicional en cada etapa de mi vida.

A mis amigos y compañeros de facultad que, con cada palabra de aliento, cada charla y cada momento compartido, hicieron que este proceso fuera más llevadero. Gracias por entender mis ausencias, por celebrar mis avances y por estar siempre cerca, incluso en la distancia.

Reconocimientos

Deseo expresar mi más profundo agradecimiento a todas las personas e instituciones que acompañaron, inspiraron y contribuyeron de distintas formas a la realización de este trabajo.

En primer lugar, a mis profesores de la Facultad, quienes no solo compartieron conocimientos técnicos y metodológicos, sino también una forma de pensar la Gestión de TI desde la ética, la investigación y la innovación. Su compromiso con la enseñanza, su exigencia académica y su capacidad para despertar la curiosidad científica fueron esenciales para mi formación profesional y personal. Cada una de sus clases dejó huellas que se reflejan en este trabajo.

Agradezco especialmente a mis líderes y mentores en el ámbito laboral, quienes me brindaron su apoyo, guía y confianza a lo largo de estos años. Gracias por haberme impulsado siempre a pensar más allá de lo evidente y a buscar soluciones innovadoras, incluso frente a los desafíos más complejos.

Extiendo también mi reconocimiento a todos los profesionales y especialistas en inteligencia artificial, biomedicina, medicina y tecnología que participaron directa o indirectamente en esta investigación. Su tiempo, sus opiniones, su experiencia y su disposición para compartir perspectivas enriquecieron de manera invaluable el análisis de este trabajo.

Índice General

Resumen.....	2
Abstract.....	3
Dedicatoria.....	4
Reconocimientos.....	5
Índice de Figuras.....	8
Índice de Tablas	9
Introducción	10
Fundamentación del tema	10
Identificación del problema	10
Justificación del problema	12
Objetivos	13
Objetivo General	13
Objetivos Específicos.....	13
Pregunta de Investigación	14
Hipótesis	14
Metodología	14
Estado del Arte.....	16
Introducción	16
Marco tecnológico FedAssist.....	17
Algoritmo Per-FedAvg	20
Control mioeléctrico basado en GAN.....	26
Sistema de control mioeléctrico basado en ML y FL	29
Privacidad Diferencial	33
Cuantificación de la Incertidumbre en el Aprendizaje Profundo.....	35
Desafío en la Adopción de Prótesis Biónicas	37
DL: Impacto en la Personalización de Prótesis Mioeléctricas.....	39
FL: Personalización y Privacidad en Datos de Usuarios	42
Reflexión final	44
Marco Teórico	46
Prótesis Mioeléctricas	46
Introducción	46
Tipos de prótesis	47
Construcción de una prótesis	48
Perspectiva mecánica	49
Perspectiva clínica	51
Control Clásico de Prótesis: PID	53
Aprendizaje Profundo: Precisión, adaptación y evolución tecnológica.....	54
¿Qué es Deep Learning?	54
Diferencias entre Deep Learning y Machine Learning.....	54

¿Cómo funciona el Deep Learning?	55
Algoritmos de Deep Learning.....	56
Métodos de Deep Learning aplicados a las señales EMG	59
Aprendizaje Federado: Un enfoque innovador y responsable	61
Aprendizaje Federado Tradicional.....	65
Aprendizaje Federado Personalizado.....	66
Aprendizaje Federado Sincrónico.....	66
Aprendizaje Federado Asincrónico.....	67
Recolección de Datos.....	68
Definiciones principales.....	68
Definición de variables	68
Determinación de población	68
Técnica utilizada	68
Datos obtenidos de la encuesta realizada a la población objetivo	69
Datos obtenidos de la entrevista realizada	77
Análisis de Datos	79
Técnica utilizada	79
Análisis detallado.....	79
Informe final de resultados	84
Conclusiones	86
Limitaciones del estudio	87
Líneas Futuras de Investigación	89
Anexos	93
Anexo I: Preguntas realizadas en el formulario de encuesta	93
Anexo II: Entrevista realizada a especialista en IA y ciberseguridad.....	95
Acrónimos.....	97
Referencias.....	99

Índice de Figuras

Figura 1 Máxima precisión de la prueba y pérdida sincronizada en cada iteración	19
Figura 2 Resultados de los datos obtenidos de los 14 estudios realizados	31
Figura 3 Riesgos y defensas a la privacidad del usuario	34
Figura 4 Representación de dónde se obtienen las señales de un miembro superior	47
Figura 5 Gráfico de los tipos de prótesis y sus clasificaciones	48
Figura 6 Circuito eléctrico integrando todos los elementos	50
Figura 7 Primeras estrategias de control utilizadas cuando se utilizan electrodos	52
Figura 8 Distribución de áreas profesionales de los participantes	70
Figura 9 Ventajas de la aplicación de Deep Learning y Aprendizaje Federado	71
Figura 10 Gráfico de barras con datos obtenidos de factibilidad de aplicación de DL	71
Figura 11 Desafíos técnicos para implementar IA en prótesis mioeléctricas	72
Figura 12 Gráfico de viabilidad técnica de aplicar FL para entrenar modelos de IA	72
Figura 13 Medidas necesarias para proteger la privacidad del usuario	73
Figura 14 Datos sensibles al usar Inteligencia Artificial	74
Figura 15 Gráfico sobre consideraciones éticas en el uso de datos de pacientes	74
Figura 16 Factores determinantes para la adopción clínica	75
Figura 17 Factores que dificultan la adopción clínica	76
Figura 18 Ponderación de potencial de Deep Learning y Aprendizaje Federado	76

Índice de Tablas

Tabla 1	Trabajos realizados utilizando algoritmos de DL con señales EMG	60
Tabla 2	Categorización de los algoritmos de FL según las dimensiones relevantes	64

Introducción

Fundamentación del tema

En la actualidad, la intersección entre la bioingeniería y la inteligencia artificial representa uno de los campos de mayor innovación tecnológica. Dentro de este contexto, las prótesis mioeléctricas han transformado la calidad de vida de personas con amputaciones; sin embargo, su dependencia de modelos de control clásicos limita su personalización y plantea desafíos críticos en el manejo de la información médica.

El presente trabajo se define como una investigación exploratoria orientada a identificar nuevas tendencias tecnológicas y señalar futuras direcciones en el área; en este marco, explora la aplicación del Aprendizaje Profundo (*Deep Learning*) y el Aprendizaje Federado (*Federated Learning*) como un enfoque emergente para superar dichas limitaciones tecnológicas. Este enfoque se centra en comprender el estado del arte y analizar los fundamentos teóricos del Aprendizaje Profundo y Federado como una tendencia tecnológica emergente frente a los métodos de control clásicos (como el algoritmo PID) para el manejo de prótesis mioeléctricas.

Asimismo, se incluye el análisis de datos obtenidos a través de una encuesta dirigida a la población objetivo y de una entrevista cualitativa a un especialista, con el propósito de evaluar el nivel de adopción y percepción del uso de *Deep Learning* y Aprendizaje Federado en prótesis mioeléctricas, identificando su potencial para mejorar la personalización de las señales electromiográficas y garantizar la preservación de los datos sensibles del usuario.

Este enfoque permite avanzar en la comprensión del problema y aportar una base conceptual que pueda ser utilizada en futuras investigaciones o desarrollos tecnológicos aplicados al área de la bioingeniería y la inteligencia artificial.

Identificación del problema

Las prótesis mioeléctricas han evolucionado significativamente en las últimas décadas, permitiendo a personas con amputaciones de miembro superior y/o inferior recuperar parte de la funcionalidad perdida mediante el control de movimientos a partir de señales electromiográficas (EMG). Estas señales, generadas por la contracción muscular del muñón,

son interpretadas por sensores y traducidas en comandos que permiten activar motores en la prótesis. Sin embargo, a pesar de los avances tecnológicos, Kyranou et al. (2018) advirtieron que uno de los principales desafíos actuales de los sistemas de control radica en su inestabilidad frente a señales que son inherentemente no estacionarias, las cuales presentan una gran variabilidad dinámica a lo largo del tiempo y exigen una profunda personalización para cada usuario.

Las consecuencias de utilizar modelos genéricos y centralizados impactan negativamente en la experiencia del paciente. En primer lugar, respecto a la falta de adaptabilidad de los modelos genéricos, Kyranou et al. (2018) explicaron que la necesidad de recurrir a reentrenamientos y calibraciones regulares genera demoras operativas que resultan sumamente frustrantes para el usuario. Por otro lado, Moreira et al. (2026) hicieron eco de esta problemática de adopción al advertir que, según la literatura especializada, entre el 20 % y el 50 % de los amputados de miembro superior terminan rechazando la prótesis debido a la falta de un control intuitivo y a la incomodidad constante.

Por otro lado, respecto a la exposición en servidores externos, Malcolm et al. (2025) advirtieron que estos modelos vulneran el derecho a la privacidad al exponer información biométrica única, ya que las bioseñales codifican atributos altamente sensibles sobre la identidad del usuario. La magnitud de esta problemática resulta significativa; de hecho, Chen et al. (2023) señalaron que la falta de un control intuitivo y personalizado es la causa principal que provoca las altas tasas de abandono de estas prótesis. Asimismo, a nivel ético, Lee et al. (2024) explicaron que muchas soluciones actuales exigen la centralización de datos, lo que genera severas preocupaciones en términos de privacidad y seguridad de la información biomédica.

Frente a este panorama, surge la necesidad de explorar alternativas tecnológicas que permitan desarrollar sistemas más precisos, adaptables y seguros. En este sentido, el uso de técnicas de *Deep Learning* combinadas con aprendizaje federado representa una propuesta prometedora. En el ámbito algorítmico, Lee et al. (2024) indicaron que el aprendizaje profundo permite mejorar significativamente la capacidad del sistema para reconocer patrones musculares complejos en las señales EMG y destacaron que la implementación del aprendizaje federado permite personalizar estos modelos sin necesidad de transferir los datos fuera del

dispositivo del usuario, protegiendo así de manera estricta su privacidad frente a posibles vulnerabilidades.

Justificación del problema

El control mioeléctrico es un campo fundamental en la ingeniería orientada a la rehabilitación. En los últimos años, el desarrollo de técnicas de aprendizaje profundo ha permitido reconocer patrones complejos en las señales EMG correspondientes a gestos o actividades musculares específicas, elevando significativamente el nivel de precisión de las prótesis mioeléctricas (Lee et al., 2024). Esta mejora técnica habilita el desarrollo de sistemas de control más personalizados y adaptativos, capaces de ajustarse a las variaciones fisiológicas de cada individuo. En consecuencia, se sientan las bases científicas y tecnológicas para prototipos de prótesis de próxima generación que ofrezcan un control más natural, preciso y personalizado al usuario amputado.

Esta investigación es de gran relevancia social dado que, según la Organización Mundial de la Salud (2017), aproximadamente el 0,5 % de la población mundial —lo que equivale a entre 35 y 40 millones de personas— necesita servicios de ortoprotésica y tratamiento de rehabilitación. Esta cifra evidencia la magnitud de los usuarios que podrían beneficiarse de manera directa de las mejoras tecnológicas y de personalización en las prótesis mioeléctricas.

Al respecto, Moreira et al. (2026) destacaron que un sistema de control protésico más preciso y personalizado se traduce en una mayor autonomía percibida para realizar actividades cotidianas, reduciendo la dependencia y facilitando la reintegración plena del individuo en la sociedad y en su entorno laboral. En esta misma línea, Moreira et al. (2026) recopilaron evidencia indicando que la calidad de vida potencialmente mejora al permitir que las prótesis respondan de forma más intuitiva a la intención motora del usuario, disminuyendo la frustración, la carga física o mental y mitigando las altas tasas de abandono asociadas a su uso prolongado.

En el plano ético y legal, surge la necesidad de soluciones tecnológicas que respeten y protejan la privacidad de los datos personales de los usuarios. Dado que las señales EMG contienen información biológica única equiparable a datos médicos sensibles, el desarrollo de este sistema se alinea con lo establecido por la Ley Argentina de Protección de Datos

Personales (Ley 25326 de 2000). Esta normativa exige garantizar la confidencialidad y el manejo responsable de la información biométrica, lo que convierte al Aprendizaje Federado en una herramienta esencial para cumplir con el principio de privacidad por diseño, asegurando que la innovación en el control de prótesis no vulnere los derechos fundamentales de los pacientes.

La justificación del problema radica en demostrar que es posible conciliar la utilidad clínica de los datos biomédicos con el derecho a la privacidad de los usuarios. Tal como sostienen Lee et al. (2024), el uso de arquitecturas descentralizadas permite entrenar modelos de control protésico más precisos y generalizables, mitigando al mismo tiempo los riesgos de exposición de la información médica sensible frente a las tradicionales bases de datos centralizadas. Atender este equilibrio podría contribuir a una adopción más amplia y confiable de las prótesis mioeléctricas avanzadas. De hecho, Calero Valdez y Ziefle (2018) plantearon que, sin la aceptación y disposición de los usuarios a compartir su información, incluso los algoritmos más perfectos carecen de sentido, situando a la privacidad de los datos como una cuestión clave. En consecuencia, los usuarios estarían mucho más dispuestos a adoptar estas tecnologías y a colaborar activamente con ellas únicamente si perciben que el sistema protege y respeta sus datos personales en todo momento.

Objetivos

Objetivo General

Determinar la viabilidad técnica y aceptación profesional de integrar el aprendizaje profundo federado en sistemas de control de prótesis mioeléctricas, orientada a mejorar la precisión funcional y garantizar la privacidad de los datos biométricos del usuario.

Objetivos Específicos

Identificar las limitaciones técnicas actuales en la personalización del control de prótesis basadas en señales EMG.

Comparar el rendimiento de arquitecturas de *Deep Learning* (como CNN, RNN, GAN) frente a métodos de control clásicos en la clasificación de intención motora.

Categorizar las estrategias de preservación de privacidad y criterios éticos necesarios para el manejo de datos biomédicos sensibles en dispositivos protésicos.

Analizar la viabilidad técnica, la aceptación clínica y las posibles soluciones arquitectónicas del Aprendizaje Profundo Federado en entornos biomédicos, a partir de la perspectiva y experiencia de profesionales del sector.

Exponer las barreras socioeconómicas y los factores clínicos determinantes que dificultan la adopción y accesibilidad de las prótesis mioeléctricas basadas en IA en el sistema de salud.

Pregunta de Investigación

¿De qué manera el uso de técnicas de *Deep Learning* Federado puede contribuir a enriquecer la personalización de un sistema de control de prótesis mioeléctricas, permitiendo una mejor interpretación de señales electromiográficas sin comprometer la privacidad del usuario?

Hipótesis

La inclusión de técnicas de *Deep Learning* Federado en sistemas de control mioeléctrico permite una interpretación de señales EMG más precisa y personalizada que los modelos genéricos, garantizando la privacidad de los patrones de contracción muscular y el historial clínico de movilidad del usuario mediante el procesamiento local en el dispositivo.

Metodología

El presente trabajo de investigación adopta un enfoque mixto (cualitativo- cuantitativo) con el propósito de obtener una visión más amplia e integral del fenómeno estudiado (Hernández-Sampieri et al., 2014). En primer lugar, se realiza una revisión exhaustiva de la literatura en los ámbitos de prótesis mioeléctricas, *Deep Learning* y Aprendizaje Federado, con el fin de relevar el estado del arte y caracterizar las variables y conceptos clave del problema. Esta vertiente cualitativa permite explorar el problema desde la perspectiva de los participantes en su ambiente natural, una aproximación idónea para abordar problemas emergentes que requieren interpretación teórica (Hernández-Sampieri et al., 2014).

A continuación, se lleva a cabo un análisis comparativo de arquitecturas y protocolos existentes de aprendizaje federado aplicados a datos biomédicos heterogéneos (señales EMG). Este análisis permite identificar brechas y oportunidades para la personalización del control protésico. Para organizar esta información, la investigación se apoya en la vertiente cuantitativa, la cual sigue un patrón estructurado que, en este caso, se tradujo en un mapa organizado de categorización de técnicas y criterios técnicos y éticos (Hernández-Sampieri et al., 2014).

Posteriormente, la validación cuantitativa del proyecto se lleva adelante mediante un cuestionario (Hernández-Sampieri et al., 2014) diseñado específicamente para evaluar los aspectos técnicos, éticos y funcionales de la propuesta. Este instrumento fue distribuido a una muestra no probabilística o dirigida, lo que permite una cuidadosa y controlada elección de casos con perfiles previamente especificados (Hernández-Sampieri et al., 2014). Esta muestra incluye a ingenieros biomédicos, investigadores en inteligencia artificial, médicos clínicos, neurocirujanos, fisiatras, kinesiólogos, especialistas en privacidad y personas interesadas en la biomedicina. El formulario se compone por un conjunto de preguntas cerradas orientadas a medir de manera estructurada las variables de interés (Hernández-Sampieri et al., 2014), tales como la viabilidad, utilidad, equidad y respeto por la privacidad del sistema propuesto.

Adicionalmente, como complemento cualitativo para profundizar en la viabilidad técnica del modelo propuesto, se realiza una entrevista a un especialista en Inteligencia Artificial y Ciberseguridad. La inclusión de testimonios en el lenguaje propio del entrevistado resulta fundamental para lograr interpretar y explicar patrones complejos desde una óptica interna (Hernández-Sampieri et al., 2014). Este instrumento se aplica con el objetivo de recabar información detallada sobre las limitaciones reales de *hardware* periférico (*edge computing*), la mitigación de la latencia y las medidas de protección criptográfica necesarias para implementar el aprendizaje federado en entornos no controlados.

Estado del Arte

Introducción

Para la construcción del presente estado del arte, se llevó a cabo una revisión sistemática de la literatura reciente en bases de datos académicas (como IEEE Xplore, ResearchGate, etc.). La búsqueda se centra en investigaciones publicadas principalmente en los últimos años, utilizando descriptores clave como 'control mioeléctrico', 'señales electromiográficas (EMG)', 'aprendizaje profundo' y 'aprendizaje federado'. El objetivo de esta selección es identificar las brechas tecnológicas actuales en la personalización de prótesis mioeléctricas y evaluar las soluciones algorítmicas emergentes que preservan la privacidad del usuario.

El desarrollo de sistemas de control para prótesis mioeléctricas ha experimentado avances significativos gracias a la evolución de la inteligencia artificial. Estas prótesis utilizan señales electromiográficas (EMG) para traducir la intención del usuario en movimientos funcionales de extremidades artificiales. No obstante, la precisión en la clasificación de señales y la adaptación personalizada siguen representando desafíos considerables, debido a que las señales EMG varían entre individuos e incluso en un mismo sujeto en distintos momentos. Esta variabilidad complica el diseño de sistemas generalizables y plantea la necesidad de métodos que permitan una personalización efectiva y continua del control protésico (Kyranou et al., 2018).

En este contexto, Faust et al. (2018) destacaron que las arquitecturas de aprendizaje profundo poseen un gran potencial para el ámbito de la salud, ya que superan el rendimiento de las técnicas convencionales de aprendizaje automático en la interpretación de señales fisiológicas. Además, los autores señalaron que una de las principales ventajas de estos algoritmos es que reducen drásticamente la necesidad de realizar ingeniería de características de forma manual.

La necesidad de cuidar los datos biomédicos responde a la creciente preocupación por la privacidad, un desafío que ha impulsado la adopción del aprendizaje federado. De acuerdo con Kairouz et al. (2021), este enfoque posibilita preservar la confidencialidad de la información al descentralizar el entrenamiento; en lugar de enviar información sensible a un

servidor central, cada dispositivo entrena un modelo de forma local y transmite únicamente los parámetros aprendidos.

Con el objetivo de mitigar la inmensa necesidad de datos que exigen los algoritmos profundos, Côté-Allard et al. (2018, citado en Kyranou et al., 2018) diseñaron un sistema de reconocimiento de gestos mediante redes neuronales convolucionales (CNN) apoyado en el aprendizaje por transferencia. En lugar de someter a un único usuario a extensas sesiones de captura de señales EMG, los autores optaron por agrupar la información de múltiples individuos para construir un modelo base generalizado. Adicionalmente, para dotar al algoritmo de mayor robustez frente a las variaciones físicas del entorno, enriquecieron la muestra inyectando datos sintéticos que emulaban perturbaciones cotidianas como el ruido eléctrico, el agotamiento muscular y los desajustes en los electrodos. Tras evaluar esta arquitectura en 17 personas sin discapacidades, la red alcanzó una exactitud *offline* del 98,31 % en la clasificación de siete posturas distintas de la mano y la muñeca.

Marco tecnológico FedAssist

En esta línea, se propone el marco tecnológico FedAssist, diseñado específicamente para integrar el paradigma federado en sistemas de decodificación de señales electromiográficas de superficie (sEMG) en prótesis inteligentes (Lee et al., 2024).

En su artículo, Lee et al. (2024) indicaron que uno de los principales obstáculos en entornos federados con señales sEMG es la naturaleza no independiente e idénticamente distribuida (*non-IID*) de los datos, producto de las diferencias individuales en los patrones musculares y del uso diverso de los dispositivos. Esta heterogeneidad compromete severamente el rendimiento de los modelos globales. Para enfrentar este desafío, FedAssist incorpora estrategias de arranque en caliente tanto a nivel local como global (*local-level* y *global-level warm-start*), lo que permite alinear los modelos para mitigar el impacto de los datos non-IID durante el entrenamiento colaborativo.

Según Lee et al. (2024), en cuanto a su arquitectura, FedAssist mantiene los datos crudos almacenados localmente en el dispositivo, compartiendo únicamente los parámetros del modelo. Esto no solo garantiza la propiedad de los datos por parte del usuario, sino que minimiza el riesgo de exposición de información médica sensible. Para lograr este entorno


descentralizado sin perder eficacia, el sistema se apoya en dos estrategias clave: el uso de conjuntos de datos auxiliares (IID) y el ajuste fino del modelo global (*fine-tuning*), alcanzando así un rendimiento robusto.

Lee et al. (2024) presentaron que las evaluaciones experimentales demuestran que FedAssist mejoró significativamente la clasificación de gestos en comparación con modelos tradicionales en escenarios con datos heterogéneos, logrando métricas superiores de precisión y una mejor adaptación al usuario. Este hallazgo resulta de especial relevancia para el desarrollo de prótesis mioeléctricas más precisas y personalizadas, ya que se verifica que la arquitectura federada no solo protege la privacidad, sino que también mantiene y mejora la eficacia en el reconocimiento de movimientos.

Como se ilustra en la Figura 1, el modelo FedAssist de Lee et al. (2024) demuestra un rendimiento superior frente a otros enfoques federados y paradigmas individuales de aprendizaje, especialmente en condiciones con datos *non-IID*. Mientras que otros modelos presentaron trayectorias de aprendizaje inestables y efectos de estancamiento, en particular en los escenarios 1 y 3 donde aumentó la heterogeneidad, FedAssist logró mantener precisión y una pérdida sincronizada más estable a lo largo de las iteraciones globales. Este desempeño resalta la robustez del enfoque propuesto en comparación con alternativas tradicionales.

Figura 1

Máxima precisión de la prueba y pérdida sincronizada en cada iteración



Nota. Obtenido de “FedAssist: Federated Learning in AI-Powered Prosthetics for Sustainable and Collaborative Learning” (p. 5), por Lee et al., 2024, *Proceedings of the 46th Annual International Conference of the IEEE EMBC*.

La investigación de Lee et al. (2024) introdujo FedAssist como una propuesta innovadora dentro del aprendizaje federado, diseñada específicamente para abordar los retos que impone la distribución *non-IID* de los datos de las señales sEMG en entornos descentralizados. A través de la incorporación de datos IID complementarios y estrategias de ajuste posteriores al entrenamiento, este marco demuestra su eficacia para consolidar modelos colaborativos más generalizables. Los resultados experimentales obtenidos en tres configuraciones distintas subrayaron el valor de integrar conocimiento distribuido entre

múltiples usuarios, promoviendo la personalización y seguridad en soluciones protésicas y de rehabilitación basadas en inteligencia artificial.

Algoritmo Per-FedAvg

Aunque el aprendizaje federado (FL) ha sido explorado ampliamente en contextos simulados, su aplicación directa en sistemas de interfaz neuronal de bucle cerrado, donde el usuario y el decodificador se co-adaptan dinámicamente, sigue siendo un terreno poco investigado. Frente a esta brecha, Malcolm et al. (2025) propusieron un marco conceptual para evaluar FL en entornos de interfaz neuronal tanto abiertos como cerrados y realizaron un experimento empírico adaptando el algoritmo Per-FedAvg. Este método, basado en el metaaprendizaje agnóstico del modelo (MAML), permite que los modelos globales actúen como puntos de partida eficientes para ser refinados con rapidez por cada usuario, sin tener que entrenarlos desde cero.

El enfoque clásico de aprendizaje federado, ejemplificado por el algoritmo FedAvg en Malcolm et al. (2025), implica que múltiples usuarios colaboren en la optimización de un único modelo compartido. Cada participante entrena localmente con sus propios datos y luego envía al servidor solo los parámetros ajustados. Este servidor, a su vez, agrega esas actualizaciones para refinar el modelo global, con el objetivo de alcanzar un rendimiento promedio eficaz entre todos los dispositivos participantes. Para FedAvg, la función de coste global $F(w)$ es la suma de todas las funciones de coste de usuario $f_i(w)$:

$$\min_{w \in \mathbb{R}^d} F(w) = \frac{1}{K} \sum_{i=1}^K f_i(w) \quad (1)$$

Para llevar a cabo este proceso, Malcolm et al. (2025) detallaron que los usuarios seleccionados ejecutan descensos de gradiente con sus propios conjuntos de datos; posteriormente, el servidor central promedia estas actualizaciones de forma ponderada. Dado que las señales fisiológicas no suelen distribuirse de manera homogénea (condición *non-IID*), los autores destacaron que se han desarrollado variantes como FedProx o SCAFFOLD, las cuales incorporan términos de regularización para estabilizar el entrenamiento. Sin embargo, para aplicaciones de interfaces neuronales donde la individualización es primordial, el algoritmo Per-FedAvg se ha consolidado como la estrategia predilecta.

A diferencia del enfoque tradicional que busca optimizar directamente los pesos del modelo global (como se observa en la Ecuación 1), la arquitectura Per-FedAvg persigue un objetivo distinto. Según describieron Malcolm et al. (2025), este modelo se diseña específicamente para alcanzar un alto rendimiento recién después de que el usuario aplique unas pocas actualizaciones de gradiente utilizando sus datos locales:

$$\min_{w \in \mathbb{R}^d} F(w) = \frac{1}{K} \sum_{i=1}^K f_i(w - \alpha \nabla f_i(w)) \quad (2)$$

Por lo tanto, el enfoque MAML utilizado en el algoritmo Per-FedAvg, busca generar un modelo inicial que, si bien no necesariamente ofrece el mejor rendimiento global, permite a cada usuario adaptarlo con rapidez a sus propios datos (como se observa en la adaptación de la Ecuación 2). Esta estrategia favorece la personalización eficiente sin necesidad de entrenar desde cero, combinando así lo mejor del aprendizaje colaborativo con la adaptación individual (Malcolm et al., 2025).

Para garantizar un marco de evaluación coherente, el estudio de Malcolm et al. (2025) se dividió en dos fases: un análisis de bucle abierto basado en datos secundarios previamente recopilados por Madduri et al. (2022, citado en Malcolm et al., 2025) y un experimento de bucle cerrado que replicó la misma tarea para permitir una comparación directa. En este diseño experimental, los investigadores utilizaron una interfaz EMG mediante la cual los participantes controlaban un cursor en pantalla, guiándolo en los ejes horizontal y vertical para seguir un estímulo visual. Esta señal de referencia fue programada superponiendo ondas sinusoidales de distintas frecuencias, una estrategia pensada específicamente para evitar la memorización de trayectorias y forzar al usuario a mantener un control activo sobre el decodificador mioeléctrico.

Para captar la actividad muscular se utilizó el sistema Quattrocento (Bioelettronica, Italia) y un sensor de alta densidad de 64 canales ubicado en el antebrazo dominante de los sujetos, quienes eran todos diestros. Las señales EMG fueron registradas a una frecuencia de 2048 Hz, procesadas con filtrado analógico y posteriormente transformadas mediante el cálculo de la envolvente lineal y un suavizado por ventana móvil. Esta secuencia de procesamiento

permitió reducir la frecuencia de muestreo a 60 Hz, generando datos más manejables para la decodificación en tiempo real (Malcolm et al., 2025).

En el marco de una simulación de aprendizaje federado de bucle abierto, Malcolm et al. (2025) decidieron comparar directamente dos enfoques distintos: el tradicional (TFL) y el personalizado (PFL), con el objetivo de identificar cuál ofrece un mejor rendimiento en tareas de decodificación EMG bajo condiciones controladas. Dado que las simulaciones permiten establecer las reglas de participación de los usuarios, optaron por un escenario síncrono, en el que todos los participantes virtuales están disponibles simultáneamente, lo cual facilita la implementación y el análisis. Para representar cada enfoque, seleccionaron dos algoritmos ampliamente reconocidos: FedAvg como punto de partida representativo del aprendizaje federado clásico y Per-FedAvg como modelo base de personalización, dada su popularidad en la literatura existente. Esta elección estratégica permite establecer líneas base sólidas tanto para investigadores nuevos como para análisis comparativos más complejos en el futuro.

En el diseño del estudio de aprendizaje federado de bucle cerrado, Malcolm et al. (2025) partieron de dos criterios clave: la heterogeneidad de los datos y las limitaciones prácticas del entorno experimental. Por un lado, dado que se asume una gran diversidad en las señales EMG entre usuarios, se consideró más apropiado emplear un enfoque de aprendizaje federado personalizado (PFL). Por otro lado, las restricciones del laboratorio, como disponer de un solo dispositivo de adquisición de datos, obligaron a realizar las pruebas de forma secuencial, es decir, entrenando a un solo participante a la vez y sin repeticiones posteriores.

Al no enfrentarse a los obstáculos típicos de los despliegues en el mundo real, como las fallas de red o las demoras de conexión de los clientes, Malcolm et al. (2025) concluyeron que no era necesario aplicar algoritmos asincrónicos robustos. En su lugar, decidieron adaptar un esquema síncrono para que funcionara secuencialmente, simplificando así la arquitectura. Los autores advirtieron que, bajo esta modalidad, al omitirse el proceso de promediado de modelos típico de FedAvg, el sistema se reduce funcionalmente a un aprendizaje local. Por estas razones, para mantener la coherencia metodológica con sus simulaciones previas, eligieron a Per-FedAvg como su algoritmo base de personalización.

En sus implementaciones, tanto en simulación *offline* como en estudios experimentales con sujetos humanos, Malcolm et al. (2025) emplearon la versión de primer orden de Per-FedAvg, la cual utiliza una aproximación simplificada de la hessiana para disminuir la carga computacional manteniendo la eficacia. Específicamente para el bucle abierto, la simulación constó de 500 ciclos globales; en cada uno, se tomaba una muestra aleatoria del 35% de los usuarios, quienes procesaban localmente 25 ajustes de gradiente. Debido a la naturaleza de este muestreo aleatorio, los clientes avanzaban a distintos ritmos hasta alcanzar su última actualización de datos, momento en el cual su modelo quedaba fijo hasta finalizar el experimento.

Por otro lado, las exigencias de respuesta inmediata del entorno de bucle cerrado obligaron a estructurar el entrenamiento en bloques más pequeños. Malcolm et al. (2025) dividieron cada segmento de 20 segundos de datos en seis lotes, procesando 40 rondas de actualización para garantizar la velocidad de respuesta. Además, como en el laboratorio sólo participaba un usuario a la vez, el servidor central no podía promediar múltiples modelos. Para resolverlo, los investigadores modificaron el algoritmo para que calculara un promedio ponderado entre el decodificador local del individuo y el modelo global. Al utilizar modelos lineales, esta técnica funciona de manera análoga al método SmoothBatch, brindando un efecto de regularización que evita que la personalización local se desvíe demasiado del conocimiento global.

En su diseño de evaluación para el estudio de bucle abierto, Malcolm et al. (2025) establecieron un experimento estructurado a partir de dos variables intrasujeto principales: por un lado, analizaron el tipo de algoritmo empleado (comparando el enfoque local clásico con los métodos federados FedAvg y Per-FedAvg) y, por otro lado, evaluaron el rendimiento bajo dos escenarios de validación distintos (pruebas dentro de un mismo individuo frente a pruebas cruzadas entre diferentes sujetos).

Para evaluar el rendimiento de los modelos desarrollados, se adoptaron dos enfoques de validación cruzada utilizando siete particiones (*k-fold* con $k=7$). En el análisis intrasujeto, la información de cada paciente se dividió en siete partes, reservando secuencialmente una de ellas para pruebas y las demás para entrenamiento. En contraste, para la evaluación intersujeto, se crearon grupos aleatorios de personas; en cada ronda, un grupo completo actuaba como

conjunto de prueba mientras los datos de los demás entrenaban al modelo. Esta metodología permitió observar tanto la capacidad de personalización como la generalización de los algoritmos en contextos de variabilidad individual y poblacional (Malcolm et al., 2025).

Para el diseño experimental de su estudio de bucle cerrado, Malcolm et al. (2025) estructuraron la evaluación en torno a dos variables principales analizadas en los mismos individuos (intrasujeto). Por un lado, examinaron el impacto del algoritmo utilizado al comparar tres condiciones: un enfoque de aprendizaje local, el método federado personalizado Per-FedAvg y un decodificador estático sin coadaptación. Por otro lado, evaluaron la estrategia de inicialización de los pesos del modelo, contrastando un arranque completamente aleatorio frente a uno derivado de los resultados de simulaciones previas.

Para analizar el comportamiento de los participantes ante decodificadores no adaptativos, se implementó una condición denominada “Estática”, en la cual los sujetos utilizaron un modelo previamente entrenado sin que se efectuarán ajustes posteriores durante la sesión experimental. Esta configuración permite evaluar el desempeño bajo decodificadores fijos, sin coadaptación. La elección de utilizar modelos locales específicos de cada individuo, en lugar de un decodificador global o uno entrenado a partir de simulaciones o datos de expertos, se fundamentó en pruebas preliminares donde los modelos genéricos no ofrecieron resultados controlables para los sujetos (Malcolm et al., 2025).

Además, se compararon dos tipos de inicialización de pesos para los algoritmos Local y Per-FedAvg: una aleatoria común a todos los sujetos y otra derivada del modelo final entrenado en simulaciones de bucle abierto. Para evitar sesgos por orden de exposición o fatiga acumulada, se aplicó un diseño experimental equilibrado mediante el uso de un cuadrado latino, asignando aleatoriamente el orden de condiciones para cada participante (Malcolm et al., 2025).

En cuanto a los resultados de la simulación de bucle abierto, Malcolm et al. (2025) comprobaron que los métodos de aprendizaje federado FedAvg y Per-FedAvg ofrecieron un rendimiento superior al enfoque de entrenamiento local en términos de precisión del control de velocidad, tanto dentro del mismo sujeto como entre diferentes sujetos. Aunque ambos algoritmos mostraron desempeños similares en general, Per-FedAvg superó significativamente

a FedAvg únicamente en las pruebas cruzadas (intersujeto). El enfoque local, por su parte, arrojó mayores errores promedio y una alta dispersión en los resultados. En materia de seguridad, los modelos federados demostraron una completa preservación de la privacidad con un riesgo empírico nulo, mientras que el enfoque local comprometió por completo la información, registrando riesgo total.

Por el contrario, Malcolm et al. (2025) observaron que, al trasladar el experimento al entorno de bucle cerrado en tiempo real, los resultados evidenciaron un claro equilibrio (*trade-off*) entre rendimiento y privacidad. Bajo estas dinámicas de coadaptación humana, el algoritmo local superó significativamente a la variante adaptada de Per-FedAvg en la precisión del control. Sin embargo, en términos de seguridad, el modelo federado mantuvo su efectividad protegiendo los datos, mientras que el modelo local siguió presentando un alto riesgo de vulnerabilidad. Estos hallazgos subrayaron el enorme desafío que supone implementar sistemas federados en interfaces neuronales adaptativas, evidenciando la necesidad de diseñar algoritmos específicos que logren mantener la privacidad sin sacrificar la respuesta clínica en tiempo real.

Como conclusión, los hallazgos obtenidos en el trabajo de Malcolm et al. (2025) representaron una contribución significativa al estudio del aprendizaje federado en el ámbito de las interfaces neuronales, abordando tanto contextos simulados como escenarios reales con interacción en tiempo real. Al poner en evidencia los desafíos técnicos que supone armonizar la protección de datos sensibles con la necesidad de adaptar los modelos a las particularidades de cada usuario, este estudio establece una base sólida para el desarrollo futuro de métodos más flexibles. En particular, resaltaron la importancia de diseñar algoritmos que logren mantener altos niveles de desempeño sin comprometer la privacidad, lo que resulta clave en aplicaciones interactivas basadas en señales neurales. El marco propuesto orienta la selección de algoritmos de aprendizaje federado según las características de los datos y la disponibilidad de los usuarios, aunque no prescribe implementaciones específicas ni garantiza un enfoque universal.

Control mioeléctrico basado en GAN

Las redes generativas antagónicas (GAN) se utilizan para generar datos nuevos y realistas a partir de datos existentes. Desde este punto de partida, Wang et al. (2025) presentaron un enfoque innovador para el reconocimiento de señales electromiográficas (EMG), fundamentado en la aplicación de una arquitectura de “conjunto abierto” basada en redes generativas antagónicas (GAN). Este método propone una mejora sustancial en la robustez y capacidad de generalización de los sistemas de control mioeléctrico, al permitir una clasificación más precisa de las señales incluso ante variaciones no contempladas en los datos de entrenamiento. La integración de técnicas GAN posibilita además la generación de representaciones sintéticas que fortalecen la estabilidad del modelo, optimizando su desempeño en contextos reales donde las condiciones musculares y eléctricas del usuario pueden presentar variaciones significativas.

En este enfoque, Wang et al. (2025) llevaron a cabo una evaluación exhaustiva del rendimiento del enfoque propuesto empleando el conjunto de datos Ninapro DB1, ampliamente utilizado en el reconocimiento de señales electromiográficas. Los resultados obtenidos evidenciaron una mejora significativa en términos de precisión y robustez al compararse con los enfoques tradicionales basados en conjuntos cerrados, así como con aquellos métodos de conjunto abierto que no incorporan redes generativas antagónicas (GAN). Esta superioridad se manifestó en diversos aspectos del rendimiento, lo que respalda la eficacia del modelo desarrollado frente a alternativas existentes en el dominio del control mioeléctrico.

Además, se llevaron adelante experimentos empíricos empleando *hardware* físico real y se recolectaron muestras auténticas de señales electromiográficas (EMG) con el objetivo de validar el enfoque propuesto. En este proceso, Wang et al. (2025) utilizaron un modelo discriminador previamente entrenado para identificar y descartar clases desconocidas dentro del conjunto de señales registradas. Los resultados experimentales revelaron una mejora del 23,6% en el desempeño del sistema al incorporar dicho discriminador, alcanzando una tasa de precisión en el reconocimiento de patrones del 97,6%, lo cual respalda la eficacia del modelo para mejorar la robustez y fiabilidad en escenarios de clasificación abierta.

Con el propósito de superar las limitaciones asociadas al reconocimiento de señales en entornos no controlados, Wang et al. (2025) indicaron que se han diseñado modelos de reconocimiento de conjunto abierto capaces de gestionar datos que no pertenecen a las clases previamente entrenadas. Estos modelos incorporan intencionalmente datos atípicos o fuera de distribución, definidos como clases desconocidas, con el fin de mejorar la capacidad del sistema para distinguir entre información relevante y no relevante. Para ello, se recurre al uso de un discriminador basado en redes generativas antagónicas (GAN), el cual permite identificar y excluir de manera efectiva dichos datos desconocidos. Asimismo, el componente generador de la GAN puede emplearse para sintetizar artificialmente muestras atípicas, que luego son utilizadas en el proceso de entrenamiento del discriminador, fortaleciendo así la robustez del modelo frente a escenarios de reconocimiento abierto y la detección de anomalías.

Durante la etapa de preprocesamiento, Wang et al. (2025) muestrearon las señales electromiográficas (EMG) de superficie y se registraron mediante diez electrodos con una frecuencia de muestreo de 1000 Hz, agrupándolos en segmentos de 200 ms que luego son procesados por un clasificador CNN. Durante la adquisición, se ejecutan diez gestos distintos que conforman igual número de clases, de las cuales algunas se definen como desconocidas y otras como conocidas para el entrenamiento de los modelos CNN y GAN. Posteriormente, una fracción de las muestras de ambas categorías se reserva para la validación del discriminador, dividiéndose el conjunto total de datos en particiones destinadas a entrenamiento, validación y prueba.

En la segunda fase, Wang et al. (2025) explicaron que se implementó un clasificador basado en redes neuronales convolucionales (CNN) orientado a la identificación de muestras pertenecientes a clases conocidas. La arquitectura del modelo incluye dos capas convolucionales seguidas de dos capas totalmente conectadas. La entrada consiste en una matriz de tamaño $N_{\text{Channel}} \times N_{\text{Sample}}$, que representa las señales EMG obtenidas de diez electrodos en intervalos temporales de 200 ms. Cada capa convolucional aplica 32 filtros de 3×3 con relleno unitario para conservar las dimensiones de las características y la salida final se aplana antes de ingresar a la primera capa completamente conectada. La cantidad de neuronas en la capa de salida se define según el número de clases conocidas, mientras que la capa FC1 incorpora 128 neuronas, seleccionadas conforme a una escala exponencial que

optimiza la capacidad de representación del modelo.

En el tercer paso, Wang et al. (2025) indicaron que el propósito principal es entrenar al discriminador para que reconozca y descarte las muestras que pertenecen a clases desconocidas, evitando así respuestas erróneas del sistema. Para este fin, se requieren datos de señales EMG tanto conocidas como desconocidas. Dado que las muestras reales de clases desconocidas se reservan para la fase de validación, se emplea el generador de la red generativa antagónica (GAN) para producir ejemplos sintéticos que simulen dichas clases. En este proceso, el generador crea vectores a partir de ruido gaussiano aleatorio, mientras que el discriminador aprende a diferenciar entre las señales reales y las generadas, estableciendo así un equilibrio competitivo entre ambas redes durante el entrenamiento.

El estudio de Wang et al. (2025) propone un enfoque innovador de reconocimiento de conjuntos abiertos sustentado en redes generativas antagónicas (GAN), orientado a incrementar la precisión y estabilidad de los sistemas de control mioeléctrico. Este método permite identificar y descartar gestos no reconocidos sin comprometer la exactitud en la detección de movimientos válidos, logrando mejoras significativas tanto en la estabilidad general del sistema como en la reducción de la tasa de error activo (TEA). Los resultados experimentales evidencian una precisión del 97,6% para los gestos conocidos y una disminución del 23,6% en la TEA, lo que confirma la efectividad del enfoque propuesto.

Sumado a su rendimiento métrico, este método se destaca por su reducida demanda computacional, una característica clave que viabiliza su instalación en dispositivos de borde (*edge devices*), como las unidades de control en prótesis físicas. Según concluyeron Wang et al. (2025), el hecho de que este sistema logre operar con éxito sin requerir un entrenamiento previo con los gestos desconocidos comprueba su robustez frente a la heterogeneidad de los datos, proyectándose como una solución altamente adaptable a la variabilidad clínica que existe entre distintos pacientes y sesiones de uso.

No obstante, los autores advirtieron que aún persisten desafíos vinculados al rendimiento en contextos de dominios cruzados (*cross-domain*, como la variabilidad al cambiar de paciente) y a la mejora de la robustez frente a gestos conocidos, lo que abre importantes oportunidades de optimización. Para futuras investigaciones, los autores plantean combinar

este enfoque con técnicas de rechazo basadas en la confianza, buscando así aumentar la fiabilidad en la toma de decisiones, e incorporar el aprendizaje por transferencia (*transfer learning*) para potenciar la adaptación entre distintos dominios. Asimismo, proyectan extender esta arquitectura hacia la estimación de ángulos articulares y momentos, ampliando significativamente su potencial para el procesamiento de bioseñales en la rehabilitación motriz (Wang et al., 2025).

Sistema de control mioeléctrico basado en ML y FL

Zaim et al. (2025) examinaron de manera integral las metodologías contemporáneas de aprendizaje automático y aprendizaje profundo aplicadas al procesamiento de señales electromiográficas (EMG) y electroencefalográficas (EEG) en el contexto de la rehabilitación de personas con discapacidad. Compararon las ventajas y limitaciones de los distintos modelos, valoraron su efectividad en la mejora de la precisión y eficiencia de los procesos de rehabilitación y analizaron la relevancia de combinar ambas señales para optimizar los resultados de recuperación. Asimismo, buscaron identificar las tendencias emergentes y las proyecciones futuras en el uso de estas tecnologías dentro del ámbito biomédico.

En su revisión sobre las tecnologías emergentes para asistir a estos pacientes, Zaim et al. (2025) destacaron diversas herramientas orientadas a restaurar tanto la capacidad motora como cognitiva. Entre las soluciones analizadas resaltan el sistema Myro, que emplea sensores de contacto y fuerza para reeducar la coordinación y el equilibrio espacial mediante actividades terapéuticas inmersivas. Asimismo, los investigadores subrayaron la viabilidad clínica de la órtesis MyoPro, un exoesqueleto que interpreta las bioseñales musculares EMG superficiales para asistir físicamente el movimiento en personas con parálisis o debilidad severa. En el campo de las interfaces cerebro-computadora (BCI), mencionan la eficacia del dispositivo IpsiHand, el cual decodifica la actividad cerebral (EEG) del hemisferio no afectado en pacientes con accidente cerebrovascular crónico para controlar una mano robótica, fomentando la neuroplasticidad motriz con márgenes muy bajos de efectos adversos.

Según indicaron Zaim et al. (2025) en las características de su revisión, del total de catorce investigaciones seleccionadas, la mayoría adoptó un enfoque prospectivo, priorizando la recopilación de datos en tiempo real durante el desarrollo de los experimentos frente al diseño retrospectivo basado en historiales clínicos previos. Como se observa en la Figura 2(a),


esta distribución refleja una clara tendencia metodológica hacia la obtención de información actualizada y contextual. Paralelamente, la evolución de las publicaciones (Figura 2(b)) evidencia un incremento pronunciado en los últimos años, lo que demuestra un creciente interés de la comunidad científica por aplicar el aprendizaje profundo al análisis de señales biomédicas.

En relación con la naturaleza de los datos procesados, Zaim et al. (2025) observaron una marcada preferencia por las señales electromiográficas (EMG) exclusivas en la mayoría de las investigaciones, en contraste con una minoría de trabajos que optaron únicamente por enfoques electroencefalográficos (EEG). Tal como ilustra la Figura 2(c), la convergencia de ambas modalidades en un mismo sistema fue la estrategia menos frecuente. No obstante, los autores destacaron que la fusión de información EMG y EEG constituye una vía altamente prometedora para incrementar la adaptabilidad y precisión del reconocimiento motriz. Al respecto, señalan que herramientas de vanguardia, como las redes convolucionales de gráficos (GCN) y la conectividad funcional, son fundamentales para materializar esta integración, ya que logran fortalecer y decodificar el vínculo directo entre la actividad cerebral y la respuesta neuromuscular.

Por otro lado, Zaim et al. (2025) mostraron que la mayoría de los estudios revisados trabajaron con participantes sanos, quienes no presentaban alteraciones neurológicas, musculares o psicológicas, ni habían sufrido eventos cerebrovasculares como se indica en la Figura 2(d). Solo una minoría incluyó tanto sujetos sanos como pacientes con condiciones específicas, entre ellos individuos con lesiones medulares o amputaciones post-ictus. En algunos casos, se analizaron señales EEG de personas con amputaciones por encima del codo, quienes, pese a su condición física, fueron consideradas neurofisiológicamente sanas al no mostrar alteraciones cerebrales. Finalmente, ciertos estudios no detallaron el estado clínico de los participantes, lo que evidencia la necesidad de mayor estandarización en la caracterización de las poblaciones estudiadas.

Figura 2

Resultados de los datos obtenidos de los 14 estudios realizados



Nota. Obtenido de “Machine Learning- and Deep Learning-Based Myoelectric Control System for Upper Limb Rehabilitation Utilizing EEG and EMG Signals: A Systematic Review” (p. 11) por Zaim et al., 2025, *Bioengineering*, 12(144).

El diseño metodológico de esta revisión sistemática de Zaim et al. (2025) partió de una búsqueda inicial de 31 publicaciones enfocadas en la aplicación de inteligencia artificial para la recuperación motora de miembros superiores. Tras aplicar filtros de exclusión rigurosos, la muestra final se consolidó en 14 estudios orientados al uso de bioseñales (EEG y EMG) en pacientes con accidente cerebrovascular. Destaca en esta selección una clara preferencia por los diseños prospectivos ($n=11$) enfocados en recabar información empírica en tiempo real, relegando los enfoques retrospectivos a una minoría de tres investigaciones.

Al analizar las arquitecturas computacionales, Zaim et al. (2025) identificaron una adopción muy pareja entre los enfoques de aprendizaje automático clásico ($n=5$) y el aprendizaje profundo ($n=6$), además de algunas configuraciones híbridas. Entre las

herramientas predictivas sobresalieron los bosques aleatorios (RF), las redes neuronales convolucionales (CNN) y las arquitecturas recurrentes LSTM. Para asegurar la fiabilidad de estos modelos, la mayoría de los investigadores implementaron validaciones cruzadas (especialmente la partición *k-fold* de cinco pliegues), reportando un rango de exactitud general sumamente amplio que osciló entre un mínimo de 70,83% y un tope de 99,23%.

Paralelamente, Zaim et al. (2025) subrayaron que uno de los hallazgos centrales de la literatura es el beneficio clínico de fusionar las lecturas EEG y EMG, ya que esta integración potencia notablemente la adaptabilidad del sistema al decodificar las intenciones motoras. Sin embargo, advirtieron que este paradigma intermodal enfrenta importantes barreras técnicas de cara a su implementación en tiempo real, tales como la susceptibilidad a las interferencias por ruido, la inestabilidad física de los electrodos y la enorme carga de procesamiento requerida. Asimismo, determinaron que la fase de extracción de características (tanto en el dominio temporal como en el frecuencial) sigue siendo el pilar crítico que define el éxito de los modelos de aprendizaje automático convencionales.

A nivel de rigor científico, la evaluación interna de los artículos reveló un panorama muy positivo: once trabajos alcanzaron la calificación de "alta calidad" y otros tres fueron catalogados como "superiores a la media". Los estudios de la primera categoría despuntaron por su impecable diseño experimental y su aplicabilidad clínica directa. Por el contrario, aquellos con puntuaciones más modestas fallaron principalmente en dos aspectos: la transparencia respecto a la disponibilidad de sus conjuntos de datos y la falta de minuciosidad al describir sus protocolos de trabajo (Zaim et al., 2025).

Como conclusión general, Zaim et al. (2025) reafirmaron el inmenso valor que tienen estas arquitecturas algorítmicas para revolucionar los sistemas de control mioeléctrico y optimizar la rehabilitación física. No obstante, aclaran que el salto desde el entorno experimental controlado hacia el uso clínico cotidiano se encuentra actualmente limitado por desafíos de robustez y *hardware*. Para materializar soluciones sostenibles, el sector demanda imperativamente la optimización de los tiempos de respuesta de los algoritmos (operación en tiempo real) y la validación de estas herramientas mediante ensayos clínicos amplios, pasos ineludibles para lograr plataformas escalables y seguras para los pacientes.

Privacidad Diferencial

En el ámbito de la protección de la información, la privacidad diferencial se concibe como un compromiso de confianza entre quienes administran los datos y sus titulares. Según establecieron Dwork y Roth (2014) en su libro, este paradigma le garantiza al usuario que la inclusión de su información en una investigación o análisis no le generará consecuencias negativas ni de ningún otro tipo, independientemente de que el atacante posea acceso a otras fuentes de datos complementarias. La principal ventaja de esta arquitectura radica en que permite extraer conocimiento estadístico de alta precisión sobre poblaciones masivas, eliminando por completo la necesidad de recurrir a los engorrosos métodos de seguridad tradicionales, tales como la creación de cuartos limpios de datos (*data clean rooms*), la firma de acuerdos restrictivos de uso o la limitación en las vistas de la información.

La revisión realizada por Mohammadi et al. (2025) se propone como una guía integral sobre los modelos de *Deep Learning* que preservan la privacidad en la medicina. Su objetivo principal es sintetizar de manera crítica el conocimiento actual, identificar los desafíos y oportunidades más relevantes del sector y orientar las futuras líneas de investigación y prácticas clínicas.


Para lograr este propósito, los autores examinaron una amplia gama de aplicaciones médicas, tipos de datos y configuraciones de entrenamiento, prestando especial atención a cómo las decisiones arquitectónicas y los métodos de normalización impactan el equilibrio entre la precisión del modelo y la privacidad. Además de analizar el papel de la equidad (*fairness*) y evaluar empíricamente la resistencia frente a ciberataques, la revisión explora estrategias de protección alternativas, como el aprendizaje federado y la perturbación local. A partir de este análisis, brindaron recomendaciones fundamentales para el diseño de sistemas de inteligencia artificial clínica que sean robustos, seguros y equitativos (Mohammadi et al., 2025).

Desde una perspectiva teórica, la privacidad diferencial (PD) otorga una protección matemática formal que asegura que la participación de un individuo en particular no altere significativamente los resultados de un modelo. En el contexto del aprendizaje profundo, Mohammadi et al. (2025) explicaron que esta protección suele implementarse mediante el descenso de gradiente estocástico diferencialmente privado (DP-SGD). Tal como se ilustra en

la Figura 3, este método inyecta ruido controlado en los gradientes durante la fase de entrenamiento para resguardar los datos personales. Sin embargo, los autores advirtieron que esta técnica conlleva un costo: la adición de ruido puede comprometer la utilidad clínica del modelo y, frecuentemente, perjudica de forma desproporcionada a los subgrupos demográficos minoritarios, agravando posibles inequidades sanitarias.

Figura 3

Riesgos y defensas a la privacidad del usuario



Nota. (a) Durante el entrenamiento del modelo, los datos brutos de los pacientes pueden ser vulnerables a filtraciones si acceden a ellos personas no autorizadas. (b) Tras la implementación, el modelo entrenado se expone a posibles ataques de inferencia, como la inferencia de membresía, donde los adversarios buscan determinar si individuos específicos formaban parte del conjunto de entrenamiento. Obtenido de “Differential Privacy for Deep Learning in Medicine” (p. 3) por Mohammadi et al., 2025, arXiv.

El problema de mantener la confidencialidad de los datos es un tema sensible, ya que las redes neuronales profundas pueden filtrar información personal debido a la exposición de los gradientes, especialmente en entornos federados donde estos parámetros se comparten entre dispositivos. Por eso, Mohammadi et al. (2025) indicaron que para mitigar este riesgo se emplea el método DP-SGD, el cual introduce ruido controlado en los gradientes durante el entrenamiento modificando su cálculo en cada iteración. Sin embargo, los autores advirtieron que esta estrategia genera un costo insoslayable: la inyección de ruido tiende a comprometer la utilidad y precisión del modelo, obligando a los desarrolladores a establecer un delicado equilibrio (*trade-off*) entre la seguridad de los datos y la funcionalidad clínica.

Como alternativa, el marco PATE, propuesto originalmente por Papernot y colaboradores, resguarda la privacidad en el aprendizaje profundo combinando las predicciones de un conjunto de modelos independientes (denominados "maestros"), los cuales son entrenados sobre particiones disjuntas de los datos confidenciales (Mohammadi et al., 2025).

A diferencia del enfoque DP-SGD, que inyecta el ruido directamente en los gradientes durante la optimización de un único modelo, Mohammadi et al. (2025) explicaron que la arquitectura PATE aísla el proceso de aprendizaje privado mediante la agregación ruidosa de los resultados de múltiples redes. Este método, apoyado en el uso de contadores como el de momentos, permite administrar rigurosamente el presupuesto de privacidad total y suele resultar más eficaz en entornos semi supervisados donde la información sensible puede dividirse de manera óptima.

En la práctica, el método DP-SGD ha sido ampliamente adoptado en escenarios clínicos, integrándose tanto en infraestructuras centralizadas como federadas, logrando procesar múltiples modalidades de datos como imágenes médicas, registros electrónicos de salud y bioseñales, aunque los autores reconocen la existencia de otras estrategias emergentes para la preservación de la privacidad (Mohammadi et al., 2025).

A modo de conclusión, la revisión elaborada por Mohammadi et al. (2025) sintetiza los avances más recientes en la aplicación del aprendizaje profundo médico que preserva la privacidad. El estudio no solo detalla el funcionamiento, ventajas y configuración del método DP-SGD, sino que también subraya áreas críticas para futuras investigaciones, tales como el impacto de estas tecnologías en la equidad entre subgrupos demográficos, la robustez frente a ciberataques, la tensión inherente entre utilidad y privacidad y el desarrollo de estrategias alternativas para blindar los datos.

Cuantificación de la Incertidumbre en el Aprendizaje Profundo

El auge de las redes neuronales profundas (DNN) ha transformado diversos campos científicos y tecnológicos; sin embargo, He et al. (2026) advirtieron que la propensión de estos modelos a emitir predicciones incorrectas acompañadas de un exceso de confianza supone un riesgo inaceptable en áreas de alta criticidad. Frente a esta problemática, la cuantificación de

la incertidumbre (UQ) se erige como una herramienta indispensable para evaluar la fiabilidad de las respuestas más allá de la métrica clásica de exactitud. Los autores identifican que gran parte de la literatura previa clasifica los métodos de UQ basándose exclusivamente en sus arquitecturas o en principios bayesianos, omitiendo el análisis del origen de la incertidumbre, lo que supone un obstáculo a la hora de seleccionar y aplicar estas soluciones en escenarios reales.

A partir de esta brecha teórica, He et al. (2026) estructuraron una taxonomía centrada en dos fuentes primarias: la incertidumbre de los datos (aleatoria) y la del modelo (epistémica). La primera constituye una característica inherente a la variabilidad de la información —como el ruido de los instrumentos de medición o las discrepancias en el etiquetado— y se define como irreducible, ya que no disminuye al incrementar el tamaño del conjunto de entrenamiento. En contraste, la incertidumbre epistémica surge de las carencias informativas o estructurales durante la fase de optimización, tales como la escasez de datos o el uso de arquitecturas subóptimas y posee la ventaja de poder mitigarse a medida que se inyecta mayor conocimiento empírico al sistema.

Para gestionar el ruido inherente a los datos, He et al. (2026) dividieron las aproximaciones metodológicas en modelos discriminativos y generativos. Los primeros suelen recurrir al cálculo de distribuciones paramétricas o a la construcción de intervalos de predicción (PI) para delimitar la variabilidad. Por su parte, los modelos generativos profundos (DGM), en especial los auto encodificadores variacionales (VAE) y los modelos de difusión, destacan por su capacidad para procesar la incertidumbre en resultados estructurados y altamente dimensionales, como es el caso de las imágenes.

De manera transversal, a la hora de enfrentar la incertidumbre del modelo, los autores advirtieron que, si bien existen técnicas muy robustas, como las redes neuronales bayesianas (BNN) o los métodos de ensamble profundo, su adopción práctica se ve frecuentemente frenada por el excesivo costo de procesamiento computacional y los enormes requerimientos de almacenamiento que exigen (He et al., 2026).

Según indicaron He et al. (2026), la aplicación práctica de la UQ resulta vital en dominios críticos como el diagnóstico médico, la geociencia y el transporte autónomo. Por

ejemplo, en el ámbito clínico, cuantificar la incertidumbre capacita a los sistemas para identificar diagnósticos dudosos y delegarlos automáticamente a la revisión de especialistas, previniendo así decisiones algorítmicas que podrían tener consecuencias letales. Asimismo, en el campo de los grandes modelos de lenguaje (LLM), los autores destacaron que la UQ es una herramienta fundamental para mitigar las "alucinaciones" (generación de contenido fabricado), ya que incrementa la confiabilidad de los textos generados al analizar tanto la probabilidad a nivel de tokens como la consistencia semántica global de la respuesta.

Finalmente, He et al. (2026) proyectaron que el futuro de la investigación en este campo se orientará hacia la convergencia entre la cuantificación de la incertidumbre y la explicabilidad de la inteligencia artificial (XAI). La premisa de los investigadores es que, al comprender no sólo el grado de duda de un modelo, sino los motivos subyacentes que generan esa inseguridad, será posible diseñar plataformas tecnológicas radicalmente más transparentes y robustas. Sumado a esto, subrayaron la urgencia de optimizar la eficiencia computacional de los modelos de difusión y de adaptar las arquitecturas de UQ para que logren procesar datos con estructuras altamente complejas, tales como los grafos y las series temporales con fuertes dependencias espaciales.

Desafío en la Adopción de Prótesis Biónicas

A pesar de la indiscutible relevancia de los dispositivos de asistencia, las tasas de abandono entre usuarios de prótesis de miembro superior siguen siendo críticamente altas. Al respecto, Moreira et al. (2026) señalaron que los pacientes tienden a rechazar estas herramientas debido a las restricciones operativas que presentan, la ausencia de una interfaz de manejo que resulte natural y el *discomfort* generado durante su uso prolongado. Si bien las prótesis cosméticas priorizan la estética, los autores explicaron que las soluciones mecánicas, particularmente las mioeléctricas, alcanzan mayores índices de aceptación cuando logran ofrecer mejoras tangibles en la ejecución de tareas diarias y permiten una manipulación de objetos de carácter más biomimético.

A nivel técnico, el uso de electromiografía de superficie (sEMG) es el método predilecto para capturar la intención neuromuscular por su naturaleza no invasiva, aunque presenta serios obstáculos de procesamiento. Moreira et al. (2026) explicaron que estas bioseñales son inherentemente estocásticas y registran amplitudes extremadamente bajas

(frecuentemente inferiores a los 4 mV), volviéndolas vulnerables al ruido ambiental y a la superposición eléctrica de los músculos adyacentes, fenómeno conocido como *crosstalk*. Esta interferencia restringe drásticamente la selectividad espacial de los electrodos, volviendo sumamente complejo el desafío de identificar y separar la contracción voluntaria perteneciente a un único dedo.

Para asegurar la fidelidad de la información antes de la conversión analógico-digital, resulta imperativo implementar una etapa de acondicionamiento robusta. En la arquitectura que desarrollaron, Moreira et al. (2026) emplearon un amplificador de instrumentación INA125 gracias a su elevada impedancia de entrada, acoplándolo a una cadena de filtrado activo Sallen-Key de segundo orden. Este circuito permitió acotar la señal a un pasabanda de 12 Hz a 300 Hz, rango que preserva los componentes espectrales vitales de la contracción muscular, mientras que un filtro *notch* adicional se encargó de suprimir la interferencia electromagnética de 50 Hz proveniente de la red eléctrica.

A diferencia de los enfoques basados en aprendizaje profundo, que suelen acarrear un costo computacional prohibitivo para sistemas embebidos, la arquitectura determinista ofrece una alternativa eficiente y de mínima latencia. Para implementarla, Moreira et al. (2026) diseñaron un *software* estructurado en tres capas, el cual incluye una rutina de interrupción (ISR) configurada a 1 kHz que se encarga del muestreo constante y del cálculo del valor eficaz (RMS) de la señal. Este flujo de datos alimenta a una máquina de estados finitos que decodifica la intención motora del usuario en tiempo real, habilitando la actuación simultánea e independiente de cada dedo de la prótesis.

En cuanto a la validación física, Moreira et al. (2026) integraron su sistema a una mano robótica fabricada mediante impresión 3D, dotada de un mecanismo de transmisión por tendones y servomotores de alto torque. Durante las pruebas experimentales, el prototipo exhibió una reactividad casi instantánea a los estímulos musculares, registrando retrasos mecánicos que oscilaron entre 314 ms y 650 ms, dependiendo del dedo accionado. Sumado a esto, las mediciones arrojaron capacidades de sujeción máxima de hasta 4,07 N, validando la fiabilidad del diseño mecatrónico y su solvencia para ejecutar patrones de agarre coordinados de forma autónoma.

DL: Impacto en la Personalización de Prótesis Mioeléctricas

El aprendizaje profundo (Deep Learning) ha demostrado mejorar significativamente el control personalizado de prótesis mioeléctricas. Como comentaron en su artículo Zbinden et al. (2024), a diferencia de los métodos clásicos de reconocimiento de patrones (por ejemplo: SVM, LDA, redes neuronales simples), las redes profundas pueden extraer automáticamente características de las señales EMG y adaptarse mejor a las variaciones individuales. Según los resultados de estos investigadores, los modelos de Deep Learning superan a las redes poco profundas al decodificar la intención motora del usuario; por ejemplo, al emplear redes neuronales profundas en sus experimentos de control en tiempo real, lograron hasta un 30% más de tasa de finalización en movimientos simultáneos y un 50% más de precisión medida en tasa de coincidencia exacta (EMR) respecto a un modelo tradicional poco profundo.

Asimismo, al evaluar a usuarios amputados, Zbinden et al. (2024) indicaron que las redes profundas mejoraron notablemente el rendimiento clínico: durante las pruebas de movimientos simultáneos de los dedos, la tasa de cumplimiento aumentó del ~80% (con el método convencional) al ~94% utilizando un modelo convolucional profundo, lo que representa un incremento de ~14 puntos porcentuales. Estos avances implican un control más fiable y preciso, adaptado a las bioseñales específicas de cada usuario, lo que potencia de forma tangible la personalización de la prótesis mioeléctrica.

Algoritmos Más Utilizados en Prótesis Mioeléctricas

De acuerdo con la revisión sistemática realizada por Zaim et al. (2025), en el campo del control mioeléctrico para la rehabilitación se han explorado numerosos algoritmos para decodificar las intenciones motoras, con distintos grados de adopción y éxito. Para su análisis, Zaim et al. (2025) identificaron la utilización de 26 modelos computacionales distintos, abarcando 14 métodos clásicos de aprendizaje automático y 11 arquitecturas avanzadas de aprendizaje profundo.

Sobre las técnicas clásicas, Zaim et al. (2025) indicaron que históricamente se emplearon clasificadores como *Linear Discriminant Analysis* (LDA), *Support Vector Machines* (SVM) y regresión logística, los cuales presentan la gran limitación de depender

fuertemente de una extracción manual de características de la señal. Al evaluar el rendimiento reportado en la literatura, Zaim et al. (2025) documentaron que los estudios primarios registraron exactitudes moderadas del 86,86% para SVM y 84,65% para regresión logística y destacaron que algoritmos bien ajustados como KNN y *random forest* (RF) lograron topes del 99,23% y 99,08% respectivamente. Sin embargo, los autores advirtieron que factores como la fatiga muscular, el movimiento de los electrodos y la variabilidad natural de los patrones EMG en condiciones reales limitan drásticamente la confiabilidad de estos enfoques tradicionales.

Por otro lado, respecto al uso de arquitecturas de aprendizaje profundo, Chen et al. (2023) destacaron que las redes neuronales convolucionales (CNN) han encontrado una amplia aplicación en el campo del reconocimiento de la intención de movimiento. Según estos autores, el gran éxito de las CNN radica en el diseño de sus capas convolucionales, las cuales les otorgan la capacidad de aprender información general a partir de grandes volúmenes de datos y proporcionar múltiples salidas. Para detallar esta ventaja, Chen et al. (2023) explicaron que estos modelos pueden clasificar la información bajo un enfoque de extremo a extremo (*end-to-end*), eliminando por completo la necesidad de extraer y seleccionar las características de las bioseñales de forma manual. De este modo, los investigadores afirmaron que la red aprende representaciones mucho más abstractas y efectivas puramente a través de la profundidad y amplitud de su estructura.

Respecto a las arquitecturas utilizadas para este fin, Zbinden et al. (2024) explicaron que las redes neuronales convolucionales (CNN) poseen la capacidad de procesar directamente las señales crudas (o sus representaciones en el tiempo/frecuencia), logrando extraer con gran éxito la información motora subyacente en el EMG a través del aprendizaje de representaciones.

Además, en el ámbito del aprendizaje profundo, los modelos basados en redes neuronales convolucionales (CNN) presentaron resultados muy variables. Zaim et al. (2025) evidenciaron que una arquitectura CNN estándar llegó a mostrar un rendimiento bajo con apenas un 56% de exactitud. En contraparte, al utilizar arquitecturas optimizadas e híbridas, Zaim et al. (2025) destacaron un modelo que combinó CNN y LSTM utilizando una red residual (ResNet), el cual logró alcanzar un 98% de exactitud en la clasificación de bioseñales.

Por otro lado, Zbinden et al. (2024) señalaron la efectividad de los modelos híbridos y las redes recurrentes. Dado el carácter secuencial de las señales musculares, los autores destacaron que arquitecturas como las redes neuronales recurrentes (RNN), las redes de memoria a corto plazo (LSTM) y las redes convolucionales temporales (TCN) son frecuentes para modelar la dinámica temporal. En la práctica, Zbinden et al. (2024) detallaron que se suelen combinar enfoques de extracción (aprovechando la CNN para obtener características instantáneas) con módulos secuenciales, logrando así decodificar el movimiento con un rendimiento superior frente a enfoques sencillos.

Finalmente, en lo que respecta a las redes especializadas en secuencias temporales, Zaim et al. (2025) documentaron que un modelo híbrido compuesto por una red LSTM y un *Stacked Autoencoder* (SAE) alcanzó un 99,01% de exactitud general y un 99,77% de especificidad. En esta misma línea, los estudios comparativos recopilados por Zaim et al. (2025) demostraron que las arquitecturas recurrentes puras, como LSTM y GRU, se posicionaron sistemáticamente entre las de mejor desempeño, con tasas de acierto que escalaron hasta un 97,70%.

Por último, respecto al uso de arquitecturas como las redes generativas adversarias (GAN), Gouda et al. (2023) señalaron que su principal fortaleza en los sistemas mioeléctricos no radica en la clasificación directa, sino en el aumento de datos para mejorar la robustez del modelo. Según explicaron estos investigadores, las GAN se han utilizado con éxito para generar señales sEMG sintéticas de alta calidad que imitan los patrones musculares reales; de este modo, Gouda et al. (2023) afirmaron que esta síntesis de información permite entrenar modelos de aprendizaje profundo mucho más generalizables, solucionando la escasez de muestras clínicas que suele causar sobreajuste (*overfitting*) y mejorando significativamente la precisión general del sistema.

Para abordar la inestabilidad del sistema frente a movimientos imprevistos, Wang et al. (2025) propusieron un enfoque innovador utilizando redes generativas antagónicas (GAN) para el reconocimiento de conjuntos abiertos (*open-set*). En la práctica, los autores explicaron que, si este discriminador detecta un patrón no reconocido, el sistema rechaza la salida y mantiene la prótesis en su estado predeterminado, previniendo la ejecución de acciones erróneas.

Al evaluar el rendimiento de esta arquitectura, los resultados de Wang et al. (2025) demostraron una altísima eficacia. Los autores documentaron que el discriminador basado en GAN logró un 97,60% de exactitud en la clasificación de acciones conocidas. Aún más importante, Wang et al. (2025) destacaron que, al detectar y rechazar activamente los gestos no conocidos, el modelo logró mejorar la tasa de error activo en un 23,60%. Finalmente, los investigadores concluyeron que este enfoque es computacionalmente eficiente y sumamente adecuado para ser implementado de manera local en dispositivos de borde (*edge devices*) con recursos limitados.

Esto muestra que las GAN pueden contribuir tanto a la personalización (al simular variaciones específicas de usuarios) como a la fiabilidad del control. En cuanto a otras técnicas como FitDNN, su mención en la literatura de prótesis mioeléctricas es escasa; la mayoría de los avances se enfocan en las arquitecturas profundas convencionales antes descritas.

FL: Personalización y Privacidad en Datos de Usuarios

Al extraer los datos de rendimiento del estudio de simulación, Malcolm et al. (2025) reportaron que las arquitecturas federadas (tanto FedAvg como Per-FedAvg) demostraron una superioridad estadística frente a los modelos locales, logrando reducir significativamente el error de velocidad en el control de la interfaz. En concreto, los enfoques federados mejoraron la precisión promedio en 0,0102 cm/s para las pruebas intrasujeto y en 0,231 cm/s en las evaluaciones intersujeto. Asimismo, la recolección de los datos evidenció que el algoritmo de entrenamiento puramente local no solo registró los mayores márgenes de error promedio, sino que también presentó la mayor varianza o dispersión de resultados entre los participantes.

En lo respectivo a la métrica de seguridad de la información, los datos recolectados en el estudio evidenciaron una dicotomía absoluta vinculada directamente a la arquitectura empleada. Malcolm et al. (2025) determinaron que la exposición de los datos depende del diseño del algoritmo: mientras que la validación del modelo local registró un riesgo empírico de privacidad total (1,0), lo que implica que la identidad de los sujetos quedó completamente expuesta, las variantes de aprendizaje federado mantuvieron una vulnerabilidad nula (0,0). Estos valores estadísticos confirmaron que la arquitectura distribuida logra proteger íntegramente la información de los usuarios sin importar si la validación se realiza dentro del mismo individuo o cruzando datos poblacionales.

Por ejemplo, algoritmos de *Federated Learning* aplicados a reconocimiento de gestos de mano han logrado desempeños similares a un modelo central, pero preservando la privacidad completa. En una implementación federada con datos no independientes (*non-IID*), un enfoque colaborativo reciente (FedAssist) alcanzó mejores métricas que varias alternativas centralizadas y federadas estándar. Concretamente, FedAssist logró ~62–77% de precisión en escenarios desafiantes, superando a FedAvg (~53–73% en las mismas pruebas) y a otros métodos federados avanzados (Lee et al., 2024). Esto demuestra que, mediante FL, se puede obtener un modelo robusto y generalizable a partir de muchos usuarios a la vez que se afinan los detalles a nivel individual, todo ello sin comprometer la confidencialidad de los datos.

Para comprender la magnitud de la recolección de datos en entornos de aprendizaje federado (*cross-device*), es necesario observar las dimensiones de las muestras involucradas. De acuerdo con Kairouz et al. (2021), este modelo se aplica típicamente sobre poblaciones totales masivas que oscilan entre un millón y 10.000 millones de dispositivos. Sin embargo, la recolección de información no se realiza de forma simultánea ni cruda; para cada ronda de comunicación, el servidor extrae actualizaciones de una muestra paramétrica limitada de entre 50 y 5.000 dispositivos cliente. En un proceso de entrenamiento completo, que puede requerir entre 500 y 10.000 rondas a lo largo de 1 a 10 días, el sistema logra agregar los datos matemáticos de hasta 10 millones de dispositivos únicos sin haber extraído la información de origen.

Desde el punto de vista estadístico, la recolección descentralizada impone el reto de que las muestras locales no son independientes e idénticamente distribuidas (*non-IID*). Al respecto, Kairouz et al. (2021) destacaron que la recolección local genera un marcado sesgo de cantidad (*quantity skew*), lo que significa que distintos usuarios aportan volúmenes de datos drásticamente desiguales dependiendo del uso de su dispositivo. Frente a esta asimetría, promediar un único modelo global resulta subóptimo. En su lugar, Kairouz et al. (2021) indicaron que el uso de algoritmos de personalización como Per-FedAvg (*Personalized Federated Averaging*) permite que el modelo global funcione como un punto de inicio que luego se ajusta a la distribución de datos local de cada cliente utilizando apenas unos pocos pasos de gradiente, optimizando el rendimiento frente a la heterogeneidad de las muestras.

Finalmente, Kairouz et al. (2021) indicaron que la temporalidad en la recolección de los gradientes es un factor crítico para garantizar la calidad de la información. En el esquema sincrónico estándar, el servidor coordina la ronda esperando que los cientos o miles de dispositivos seleccionados en la muestra envíen sus actualizaciones de forma conjunta. Sin embargo, los autores indicaron que este mecanismo es susceptible a los rezagados (*stragglers*); es decir, dispositivos con menor capacidad de cómputo o fallas de red que retrasan el ciclo de recolección. Por ello, para un escenario de recolección en tiempo real continuo, la implementación de esquemas de transmisión asincrónica o libres de bloqueo (*lock-free*) permite a los dispositivos enviar sus pesos paramétricos en momentos distintos. Esta flexibilidad técnica minimiza la pérdida de datos por demoras y viabiliza la integración del modelo sin comprometer la cadencia de la recolección.

Reflexión final

La evidencia recopilada en el presente estado del arte demuestra que la intersección entre las interfaces mioeléctricas y el aprendizaje profundo ha alcanzado un punto de madurez diagnóstica y clasificatoria notable, superando las limitaciones predictivas de los enfoques deterministas tradicionales. No obstante, persiste una brecha crítica en lo que respecta a la resiliencia de estos sistemas frente a la variabilidad dinámica de las bioseñales —causada por factores intrínsecos como la fatiga muscular o el desplazamiento de sensores— y la gestión abierta de gestos imprevistos. Los avances en arquitecturas generativas y esquemas de coadaptación en tiempo real perfilan soluciones robustas, pero su transferencia directa a dispositivos de asistencia biónica embebidos se encuentra condicionada por la elevada complejidad computacional y las restricciones de latencia inherentes al *hardware* periférico.

Por consiguiente, el verdadero desafío de la próxima generación de prótesis inteligentes no radica únicamente en maximizar la exactitud de los algoritmos en entornos controlados, sino en resolver de manera sostenible la transición hacia la personalización continua. El análisis documental revela que los modelos centralizados genéricos tienden a fallar debido a la naturaleza heterogénea y no independiente e idénticamente distribuida (*non-IID*) de los datos neuromusculares de cada individuo. Es en este escenario donde metodologías emergentes como el meta-aprendizaje y las estrategias de arranque en caliente (*warm-start*) adquieren un rol protagónico, ofreciendo estructuras globales maleables que cada usuario puede refinar localmente con una inversión mínima de tiempo y recursos de cómputo.

Finalmente, este imperativo de personalización se topa con una barrera ética y legal ineludible: la sensibilidad de la información biométrica. La centralización de registros electromiográficos vulnera los derechos de privacidad de los usuarios, lo que exige la adopción sistemática de la privacidad por diseño. Si bien herramientas como la privacidad diferencial o el agregado de ruido en gradientes mitigan los riesgos de filtración, suelen pagar un peaje alto en la utilidad final del modelo. De este modo, la integración de arquitecturas de aprendizaje federado personalizado emerge como la alternativa más viable y prometedora, permitiendo descentralizar el entrenamiento y asegurar la soberanía de los datos médicos en el dispositivo, demostrando que es factible conciliar la máxima precisión funcional con un estricto compromiso ético y normativo.

Marco Teórico

Prótesis Mioeléctricas

Introducción


Las prótesis mioeléctricas son dispositivos artificiales diseñados para reemplazar miembros perdidos, especialmente piernas, brazos y manos. Estas herramientas cuentan con un diseño compuesto por servomotores que se controlan mediante señales eléctricas generadas por la contracción muscular del propio paciente. Estas bioseñales, conocidas como electromiográficas (EMG), se captan en la superficie de la piel y se traducen en movimientos mecánicos. Para registrar con éxito esta intención motora, el sistema requiere un amplificador bipolar de alta ganancia, capaz de multiplicar entre 200 y 5000 veces la intensidad de la señal original emitida por el músculo, operando en un espectro frecuencial de 1 a 2 kHz (Mahecha Escarraga, 2015).

Tal como se observa en la Figura 4, el músculo emite impulsos que son captados por el amplificador, el cual se encarga de acondicionar la información para gobernar los servomotores y permitir que la prótesis replique los movimientos de un brazo biológico. El principal obstáculo en esta etapa de adquisición radica en el ruido inherente a la medición, el cual puede causar severos errores de lectura y, por consiguiente, generar movimientos inexactos o involuntarios en el dispositivo (Mahecha Escarraga, 2015).

Por este motivo, Mahecha Escarraga (2015) enfatizó la necesidad indispensable de aplicar técnicas de filtrado sobre las señales extraídas. Este paso tiene el propósito de atenuar la interferencia de alta frecuencia, priorizando la conservación de los componentes de baja frecuencia y optimizando el procesamiento en aquellos registros médicos que presentan los mayores niveles de contaminación espectral.

Figura 4

Representación de dónde se obtienen las señales de un miembro superior




Nota. Obtenido de *Las Prótesis Mioeléctricas* (p. 2), por Mahecha Escarraga, 2015, Corporación Universitaria Minuto de Dios.

Tipos de prótesis

Los dispositivos protésicos admiten diversas clasificaciones taxonómicas en función de su propósito y diseño. Específicamente, estas pueden categorizarse según su funcionalidad (la extremidad específica que reemplazan), su principio de acción o movilidad, el tipo de control implementado y los mecanismos de retroalimentación incorporados (Munné Argelich, 2022), tal como se esquematiza en la Figura 5.

Figura 5

Gráfico de los tipos de prótesis y sus clasificaciones



Nota. Obtenido de *Building of a myoelectric prosthesis* (p. 26) por Munné Argelich, B., 2022, Universitat de Lleida.

Construcción de una prótesis

Las prótesis pueden ser de diferentes maneras, contener diferentes elementos y ser configuradas con diferentes programas. Para poner un ejemplo práctico de cómo puede estar constituida, Munné Argelich (2022) detalló en su proyecto la construcción de una prótesis mioeléctrica conformada por veintidós piezas impresas en 3D. Para garantizar la ergonomía, el autor basó las dimensiones estructurales en la antropometría de una mano humana real, ajustándolas posteriormente para albergar el *hardware* necesario. El modelado tridimensional requirió un enfoque híbrido, combinando SolidWorks para los dedos principales (índice, medio y anular), AutoCAD para la estructura base de la mano (pulgar, meñique, palma, muñeca y antebrazo inferior) y 123D Design para el segmento superior del antebrazo.

Perspectiva mecánica

Con respecto a la arquitectura electrónica del dispositivo, Munné Argelich (2022) declaró que el comportamiento cinemático de esta prótesis es regulado por una red de sensores que alimentan a un microcontrolador Arduino. Esta placa central es la encargada de procesar las señales y distribuir los comandos de actuación hacia seis servomotores independientes, estableciendo una conectividad mutua que el autor describe exhaustivamente en su apartado metodológico.

Posteriormente, la implementación de sensores EMG permite recolectar y procesar las corrientes bioeléctricas del tejido neuromuscular mediante electrodos de superficie. Munné Argelich (2022) detalló que este registro genera una señal cuya amplitud —comprendida entre unos pocos microvoltios y un tope de 10 mV— y frecuencia están directamente condicionadas por factores como la ubicación de los sensores, la intensidad de la contracción y la impedancia de la piel. La cuantificación precisa de estas magnitudes eléctricas resulta indispensable no solo para el diagnóstico ergonómico o las plataformas de *biofeedback*, sino que es el pilar fundamental para calcular el torque articular y gobernar fluidamente los movimientos de las prótesis mioeléctricas.


Para materializar las órdenes, la información procesada se transmite a un conjunto de servomotores. Según detalló Munné Argelich (2022), estos dispositivos operan como actuadores rotativos que superan a los motores convencionales al brindar una exactitud superior en el manejo de la aceleración, la velocidad y el posicionamiento angular. Esta característica los convierte en elementos clave para lograr una articulación artificial fluida y finamente controlada.

En paralelo a los actuadores mecánicos, la arquitectura propuesta de Munné Argelich (2022) incorpora un módulo acelerómetro. Dentro de esta prótesis, el instrumento cumple la función específica de monitorizar la orientación espacial de la mano para restringir electrónicamente los grados de flexión y extensión de la muñeca. Gracias a esta limitación del rango de movimiento, el sistema previene que la extremidad asuma posiciones forzadas, garantizando un uso ergonómico y seguro para el paciente.

Adicionalmente, según indicó Munné Argelich (2022), el diseño incluye un potenciómetro que opera como un divisor de voltaje ajustable. En el contexto particular de este desarrollo, el autor explica que las variaciones de resistencia generadas manualmente por el usuario se traducen digitalmente en el microcontrolador (mapeando valores de 0-1023 a 0-180 grados) para gobernar de forma directa al servomotor encargado de la muñeca, permitiendo afinar su comportamiento mecánico con altísima precisión.

En definitiva, Munné Argelich indicó que todo este ecosistema de *hardware* —que abarca la sensórica, el microcontrolador, los actuadores y el circuito de alimentación— opera de manera sincronizada (ver Figura 6) para transmutar la intención neuromuscular en acción mecánica, restituyendo exitosamente la funcionalidad motriz del miembro ausente.

Figura 6
Circuito eléctrico integrando todos los elementos



Nota. Obtenido de “Building of a myoelectric prosthesis” (p. 45) por Munné Argelich, 2022, Universitat de Lleida.

Perspectiva clínica


Según Ortosur (2018), el correcto ajuste de los electrodos es crucial para garantizar una lectura confiable de las señales electromiográficas. Cuando el encaje es deficiente —ya sea por estar demasiado holgado o excesivamente ajustado— puede provocar el desplazamiento del sensor, lo que impide captar adecuadamente la actividad muscular, comprometiendo así el control de la prótesis ante los estímulos esperados.

Cómo investigó Bustamante Gómez (2015), la estabilidad y funcionalidad de una prótesis dependen en gran medida del diseño y ajuste del *socket*, que actúa como interfaz entre el muñón del usuario y la prótesis. Elementos como los *liners*, generalmente fabricados en silicona y en algunos casos reforzados con pines de fijación, cumplen un doble propósito: mejoran la adhesión entre el muñón y el *socket* y permiten una colocación estratégica de los electrodos para captar con mayor precisión la actividad muscular necesaria para el control de los movimientos protésicos.

Los datos utilizados para entrenar y evaluar sistemas de reconocimiento de patrones musculares, como se ilustra en la Figura 7, suelen recolectarse bajo condiciones experimentales ideales, donde las contracciones se producen sin las interferencias propias del contexto real. No obstante, Roche et al. (2014) indicaron que cuando un paciente interactúa con la prótesis en situaciones cotidianas —por ejemplo, bajo episodios de estrés o al intentar corregir movimientos erróneos—, los patrones de activación muscular pueden variar sustancialmente. Estos mismos autores añaden que factores dinámicos como la transpiración, el corrimiento físico de los sensores y las modificaciones morfológicas del muñón tras la cirugía también impactan negativamente en la calidad de la señal EMG. Aunque los autores aclararon que algunos de estos efectos pueden mitigarse incrementando la distancia entre los electrodos o alineándolos estratégicamente con las fibras musculares, concluyen que el alto rendimiento obtenido en las validaciones de laboratorio frecuentemente no logra replicarse en los escenarios reales de uso.

Figura 7

Primeras estrategias de control utilizadas cuando se utilizan electrodos



Nota. a) Se utiliza un electrodo para generar tres estados y b) Se utilizan dos electrodos que determinan acciones opuestas. Obtenido de “Prosthetic Myoelectric Control Strategies: A Clinical Perspective” (p. 3), por Roche et al., 2014, *Curr Surg Rep*, 2(44).

Aunque las nuevas arquitecturas de control basadas en regresión se perfilan como la solución ideal al unificar las ventajas de los modelos previos, Roche et al. (2014) advirtieron que estas tecnologías aún transitan por fases de desarrollo incipientes. Asimismo, destacaron que trascender la dependencia de la retroalimentación puramente visual e incorporar estímulos sensoriales táctiles será un paso ineludible para lograr un manejo más fluido e intuitivo. Frente a este panorama, los autores propusieron que herramientas innovadoras como los Entornos Virtuales de Rehabilitación (VRE) constituyen una estrategia sumamente valiosa para mantener a los pacientes involucrados con su terapia, mitigando así las altas tasas de abandono de los dispositivos.

Control Clásico de Prótesis: PID

En su revisión integral sobre estrategias de control protésico, Abdeltwab (2025) describió que el control Proporcional-Integral-Derivativo (PID) constituye un algoritmo de

retroalimentación con una amplia adopción en la bioingeniería. Su principio operativo consiste en la acción conjunta de sus componentes proporcional, integral y derivativo para mitigar la desviación existente entre el valor de referencia establecido y la variable real cuantificada en el sistema. Para el caso específico de la asistencia biónica, el autor detalló que este mecanismo se implementa de manera regular con el propósito de regular las posiciones articulares y coordinar la activación de los elementos actuadores.

Respecto a la versatilidad de este algoritmo clásico, Abdeltwab (2025) expuso que los lazos PID se emplean de manera satisfactoria en el diseño de articulaciones artificiales de rodilla y tobillo para coordinar las trayectorias angulares en las fases de la marcha, al igual que en prótesis de miembro superior para calibrar la respuesta motora. Adicionalmente, el autor subrayó que la bajísima exigencia matemática y computacional de esta ecuación permite que la ejecución de comandos en tiempo real sea sumamente viable, incluso al operar bajo arquitecturas integradas de microcontroladores de baja potencia.

No obstante, en su análisis comparativo, Abdeltwab (2025) identificó limitaciones considerables en esta estrategia, sobre todo cuando se la expone a entornos dinámicos. En primer lugar, el investigador señaló que los controladores PID carecen de mecanismos internos de adaptación, por lo que su desempeño puede verse seriamente mermado ante alteraciones en el comportamiento del usuario o frente a comportamientos no lineales de las bioseñales. Además, advirtió que suelen exhibir una alta vulnerabilidad ante el ruido de los sensores y exigen una sintonización manual sumamente minuciosa, un proceso que resulta inviable cuando se busca una personalización veloz y continua del sistema.

A modo de síntesis, Abdeltwab (2025) concluyó que, aunque el control PID clásico se mantiene como una línea base sólida y robusta para el gobierno cinemático de prótesis, sus deficiencias en adaptabilidad lo relegan frente a los enfoques modernos inteligentes. En consecuencia, el autor argumentó que si bien el PID es funcional, las arquitecturas basadas en inteligencia artificial son las que definirán el futuro de los entornos clínicos, donde la prioridad es garantizar una interacción profundamente personalizada y capaz de adaptarse a las variables del paciente.

En este sentido, para superar las limitaciones de los controladores clásicos, Zafar et al. (2022, citado en Abdeltwab, 2025) destacaron que los modelos de aprendizaje profundo (DL) se posicionan como la solución más prometedora en el campo de la bioingeniería. Estos investigadores explicaron que dichas arquitecturas sobresalen en la extracción de patrones espacio-temporales ocultos dentro de las señales electromiográficas (EMG), logrando una precisión y una personalización del movimiento inigualables. Sin embargo, aunque el salto cualitativo es evidente, el análisis recogido por Abdeltwab (2025) a partir de estos autores advirtió que el uso de estas redes neuronales en prótesis portátiles se encuentra actualmente frenado por un gran obstáculo: la enorme carga computacional y las estrictas restricciones de consumo energético que imponen los sistemas de *hardware* embebidos.

Aprendizaje Profundo: Precisión, adaptación y evolución tecnológica

¿Qué es Deep Learning?

Según IBM (s. f.):

El *deep learning* es un subconjunto de machine learning impulsado por redes neuronales cuyo diseño se inspira en la estructura del cerebro humano. Los modelos de *deep learning* están detrás de la mayor parte de la inteligencia artificial (IA) más avanzada en la actualidad, desde la visión artificial y la IA generativa hasta los coches autónomos y la robótica. (párr. 1)

Diferencias entre Deep Learning y Machine Learning

A diferencia de los algoritmos clásicos de *Machine Learning* —que operan con lógicas matemáticas explícitas—, IBM (s. f.) destaca que el *Deep Learning* se distingue por poseer múltiples capas ocultas que le otorgan una enorme profundidad analítica. Esta arquitectura jerárquica le permite a la red no solo aprender características sumamente complejas de los datos, sino también ejecutar tareas mediante enfoques de aprendizaje autosupervisado utilizando información cruda y no etiquetada.

En lugar de requerir una guía explícita, los modelos de aprendizaje profundo son capaces de descubrir patrones granulares de manera autónoma ajustando iterativamente los

pesos y sesgos de sus conexiones. Esta versatilidad ha revolucionado la industria tecnológica, facilitando el desarrollo de herramientas de vanguardia (IBM, s. f.).

¿Cómo funciona el Deep Learning?

En cuanto a su mecánica de funcionamiento, IBM (s. f.) explicó que las redes neuronales profundas emplean una estructura de nodos interconectados (neuronas artificiales) que procesan la información mediante funciones de activación no lineales. Este procedimiento se ejecuta a través de una "pasada hacia adelante" (*forward pass*), la cual comienza en la capa de entrada recibiendo los datos vectorizados, atraviesa las múltiples capas ocultas que refinan progresivamente la información y concluye en la capa de salida, donde se genera la predicción o clasificación matemática final.

Como contraparte fundamental para optimizar este proceso, IBM (s. f.) detalló que el entrenamiento del modelo se efectúa mediante los algoritmos de retropropagación (*backpropagation*) y descenso de gradiente. Este mecanismo evalúa el margen de error de las predicciones utilizando una función de pérdida y, apoyándose en las reglas del cálculo, actualiza los pesos de las conexiones en dirección inversa a través de la red. La iteración constante de este ciclo es lo que permite que el sistema minimice sus errores y aumente su precisión analítica de forma gradual.

No obstante, IBM (s. f.) advirtió que todas estas capacidades analíticas conllevan una altísima demanda de recursos computacionales. Para solventar este desafío tecnológico, la organización detalla que la masificación del aprendizaje profundo fue posible gracias al uso de unidades de procesamiento gráfico (GPU), cuya arquitectura de alto rendimiento resulta idónea para ejecutar en paralelo las cantidades masivas de cálculos matemáticos que exige el entrenamiento. Sin embargo, dado que la gestión local de clústeres de *hardware* a nivel empresarial suele implicar costos de infraestructura sumamente elevados, IBM (s. f.) señaló que los servicios de computación en la nube (*cloud computing*) se han consolidado como la alternativa más viable para escalar estos modelos.

Asimismo, la implementación práctica de estas redes se apoya en bibliotecas y marcos de código abierto; entre los más destacados, IBM (s. f.) subrayó el uso de TensorFlow, PyTorch

y Hugging Face Transformers, plataformas que proveen módulos preconfigurados para agilizar el diseño, optimización y despliegue eficiente de las soluciones neuronales.

Algoritmos de Deep Learning

Como indicaron Faust et al. (2018), el término *Deep* en *Deep Learning* hace referencia a la profundidad de capas ocultas presentes en la arquitectura de las redes neuronales artificiales (RNA). Estas redes buscan imitar el funcionamiento del cerebro humano a través de una estructura jerárquica que incluye una capa de entrada, una o varias capas ocultas y una capa de salida. Desde un enfoque biológico, una neurona se compone de diferentes partes: las dendritas que reciben señales, el soma o cuerpo celular que procesa la información, el axón que transmite la señal y las sinapsis que actúan como conexiones. En una neurona artificial, estos elementos se representan de manera análoga: las entradas y sus respectivos pesos simulan las dendritas y las sinapsis, mientras que la función de activación cumple un rol equivalente al del núcleo celular en el procesamiento de señales.

Por otro lado, Faust et al. (2018) indicaron que las RNA presentan ciertas limitaciones frente a variaciones como traslaciones o desplazamientos en los datos de entrada, lo que puede impactar negativamente en su precisión al clasificar. Para superar este inconveniente, se desarrolló una arquitectura más robusta: las redes neuronales convolucionales (CNN), que introducen mecanismos de invariancia espacial. Las CNN son redes de tipo *feedforward* compuestas por tres tipos principales de capas: convolución, agrupación (*pooling*) y capas completamente conectadas.

En la capa de convolución, Faust et al. (2018) indicaron que los datos de entrada se combinan con un conjunto de filtros o *kernels* que permiten extraer características relevantes, generando lo que se conoce como mapas de características. El desplazamiento del filtro sobre la entrada se controla mediante un parámetro llamado *stride*. Esta operación cumple una función similar a la detección automática de patrones, lo cual resulta útil para tareas posteriores de clasificación. La capa de agrupación se encarga de reducir la dimensión espacial del mapa de características, manteniendo la información esencial. Esto se logra mediante operaciones como la agrupación máxima (*max pooling*), donde de cada región se conserva únicamente el valor más alto, disminuyendo así la cantidad de datos sin perder información relevante.

Además, Faust et al. (2018) comentaron que la capa completamente conectada establece conexiones entre todas las neuronas de la capa anterior y la actual, generando una salida que, en la capa final, suele coincidir con las clases a predecir. Cada conexión tiene un peso y se realiza una suma ponderada de las entradas para determinar el resultado. En cuanto a la función de activación, se utiliza comúnmente la ReLU con fuga (*Leaky ReLU*), que introduce no linealidad y dispersión en la red.

Tal como indicaron los autores, el entrenamiento de una CNN se lleva a cabo mediante el algoritmo de retropropagación y el rendimiento del modelo puede mejorarse ajustando adecuadamente los hiperparámetros. Además de las CNN, existen otras arquitecturas de aprendizaje profundo que también se aplican al análisis de señales fisiológicas, tales como los autoencoders, los modelos generativos profundos y las redes neuronales recurrentes (RNN), cada una con capacidades específicas para el tratamiento de datos secuenciales y complejos (Faust et al., 2018).

A diferencia de las arquitecturas tradicionales, las redes neuronales recurrentes emplean un enfoque recursivo diseñado para procesar tareas rutinarias de forma secuencial. Su rasgo distintivo radica en una memoria interna que permite que cada nueva salida dependa de los cálculos realizados previamente (Faust et al., 2018).

De acuerdo con IBM (s. f.), las redes neuronales recurrentes representan una arquitectura diseñada para procesar datos secuenciales, lo que las hace ideales para tareas como la previsión de series temporales, el reconocimiento de voz y el procesamiento del lenguaje natural. Su rasgo distintivo radica en que operan bajo un bucle recurrente que les permite utilizar el resultado de un paso previo como entrada del siguiente. Esta "memoria" interna es precisamente lo que diferencia a las RNN de las redes neuronales convencionales, las cuales solo asignan de manera lineal una única entrada a una única salida.

En cuanto a su lógica operativa, IBM (s. f.) explicó que esta recurrencia se puede entender teóricamente como si los datos atravesaran una serie de múltiples capas que comparten pesos idénticos. Gracias a este enfoque, las RNN logran mantener una comprensión del contexto y del orden temporal, facilitando que el modelo aplique esta retroalimentación en

arquitecturas que, por ejemplo, fueron introducidas de manera temprana para abordar problemas complejos como la traducción automática.

Sin embargo, IBM (s. f.) señaló que esta arquitectura presenta limitaciones fundamentales durante su entrenamiento. Al repetirse las actualizaciones de los parámetros sobre capas recurrentes idénticas, los valores pueden escalar de manera exponencial, desencadenando los problemas conocidos como explosión de gradientes (cuando se amplían excesivamente) o desaparición de gradientes (cuando se minimizan). Ambos fenómenos introducen una severa inestabilidad matemática que puede ralentizar o detener el aprendizaje por completo, restringiendo el uso de las RNN estándar a secuencias relativamente cortas.

Para mitigar estas complicaciones y superar el límite de longitud en las secuencias, IBM (s. f.) destacó que se han desarrollado mejoras sustanciales sobre la arquitectura básica. Específicamente, el documento menciona la implementación de variantes más avanzadas como las redes de memoria a corto y largo plazo (LSTM) y las unidades recurrentes con compuertas (GRU), las cuales resuelven estas deficiencias de gradiente y aumentan drásticamente la capacidad del modelo para capturar dependencias de largo alcance.

Por otro lado, dentro del ecosistema generativo, IBM (s. f.) señaló que las redes generativas adversarias (GAN) se posicionan como una arquitectura fundamental para crear datos sintéticos precisos que conservan una alta similitud con el conjunto de entrenamiento original. Este modelo se estructura en un sistema dual entrenado de manera adversaria, similar a un juego de suma cero: una red generadora produce nuevas muestras, mientras un discriminador evalúa si son reales o falsas. A medida que el ciclo avanza iterativamente, el generador perfecciona sus imitaciones hasta engañar al discriminador. No obstante, si bien estas arquitecturas producen ejemplos increíblemente precisos, la institución tecnológica advierte que esta misma dinámica de confrontación provoca que el entrenamiento sea intrínsecamente inestable y complejo.

Por otro lado, de acuerdo con Stelzer et al. (2021), las redes neuronales profundas (DNN) han emergido como una de las soluciones de aprendizaje automático más poderosas y versátiles. Estos autores detallaron que, gracias a su capacidad de aprender representaciones directamente de los datos, las DNN han logrado resultados sobresalientes en una amplia gama

de dominios complejos, incluyendo la visión por computadora, el aprendizaje por refuerzo, los sistemas robóticos, el diagnóstico médico y el procesamiento del lenguaje natural.

No obstante, Stelzer et al. (2021) advirtieron que la sofisticación de estas arquitecturas plantea serios desafíos de *hardware* cuando se intenta implementarlas en plataformas no tradicionales, como los sistemas electrónicos o fotónicos. Según los investigadores, estas alternativas aún enfrentan limitaciones técnicas significativas que restringen de manera severa el tamaño y la funcionalidad de las redes en dichos entornos.

Para superar este obstáculo físico, Stelzer et al. (2021) propusieron un enfoque radicalmente distinto basado en el "plegado temporal" de la arquitectura, al cual denominaron red neuronal profunda plegada en el tiempo (Fit-DNN). Los autores explicaron que este modelo logra reemplazar la inmensa complejidad estructural de una red de múltiples capas y nodos por una única neurona artificial que interactúa consigo misma. Según detallaron Stelzer et al. (2021), esto se consigue implementando bucles de retroalimentación con retardos temporales que modulan las señales a lo largo del tiempo, permitiendo simular las conexiones sinápticas ajustables entre las capas ocultas. En esencia, cada instante temporal en este circuito representa un "elemento virtual" de la red original, logrando una emulación funcional exacta de una DNN tradicional sin la necesidad de replicar físicamente una gran cantidad de componentes.

Métodos de Deep Learning aplicados a las señales EMG

Tal como investigaron Faust et al. (2018), las señales electromiográficas (EMG) reflejan en simultáneo la activación, la fuerza y el estado general del músculo. Dado que la medición capta y suma las contribuciones de todas estas fuentes al mismo tiempo, los autores advierten que resulta muy complejo aislar e interpretar un único aspecto a partir de la señal obtenida. Para abordar esta complejidad, diversos estudios han implementado redes neuronales; un resumen de estos algoritmos de aprendizaje profundo aplicados al ámbito sanitario, junto con los datos utilizados y sus resultados, puede observarse en la Tabla 1.

Tabla 1*Trabajos realizados utilizando algoritmos de DL con señales EMG*

Autor	Aplicación	Algoritmo DL	Datos	Resultados
Xia et al., 2017	Estimación de movimiento	RNN	Mediciones de 8 sujetos sanos	RNN supera a otros métodos en la estimación de trayectoria 3D
Zhai et al., 2017	Control de neuroprótesis	CNN	Base de datos NinaPro DB 2 & 3	Precisión: 83,00%
Park et al., 2016	Decodificación de intención	CNN	Datos cinemáticos y EMG de NinaPro DB	Precisión: > 90,00%
Atzori et al., 2016	Clasificación de movimientos	CNN	Base de datos NinaPro DB	Precisión: 66,59%
Geng et al., 2016	Reconocimiento de gestos	CNN	18 sujetos, 16 gestos, 10 repeticiones	Precisión: 99,50%
Wand y Schmidhuber, 2016	Reconocimiento de voz	DNN	Corpus EMG-UKA	DNN supera a GMM en la etapa frontal
Allard et al., 2016	Guiado de brazo robótico	CNN	18 sujetos realizando 7 gestos	Precisión: $\approx$ 97,90%
Wand y Schultz, 2014	Reconocimiento de voz	DNN	25 sesiones de 25 sujetos	Visualización de la actividad de nodos ocultos

Nota. Obtenido de “Deep learning for healthcare applications based on physiological signals: A review” (p. 10) por Faust et al., 2018, *Computers in Biology and Medicine*, 100.

Aprendizaje Federado: Un enfoque innovador y responsable

En este sentido, Kairouz et al. (2021) plantearon que el aprendizaje federado se posiciona como un enfoque innovador y responsable para abordar los desafíos de personalización. A diferencia del paradigma tradicional del aprendizaje automático, estos autores explican que bajo esta arquitectura la información cruda nunca abandona el dispositivo del usuario. Para complementar esta dinámica, Rieke et al. (2020) detallaron que esta tecnología propone, en esencia, llevar el modelo hacia los datos en lugar de trasladar los datos al modelo.

Aplicando este concepto y basándonos en el paradigma descrito por Kairouz et al. (2021), en la práctica de esta investigación esto significa que la entidad local (como la unidad de control de la prótesis o un dispositivo móvil asociado) será la encargada de entrenar un modelo de aprendizaje profundo utilizando las señales EMG particulares del paciente, para luego enviar al servidor central únicamente los ajustes o actualizaciones de los parámetros.

En cuanto a la arquitectura de este sistema, Rieke et al. (2020) explicaron que el servidor central actúa como un coordinador clave o "intermediario honesto" dentro de una topología de red conocida como "centro y radios" (*hub and spoke*). En este diseño, la entidad central se encarga de gestionar los ciclos iterativos de entrenamiento: primero distribuye un modelo global inicial, luego recibe únicamente las actualizaciones matemáticas (como los parámetros o gradientes) calculadas localmente por cada cliente y finalmente agrega estas contribuciones para formar un modelo de consenso. Según detallaron los autores, este proceso se repite continuamente y el modelo actualizado es redistribuido a cada dispositivo, lo que ofrece la gran ventaja de abstraer los mecanismos internos del sistema, brindando mayor agilidad y permitiendo incluso que las instituciones médicas participantes permanezcan en el anonimato entre sí.

A lo largo de este ciclo operativo, las bioseñales EMG de carácter personal permanecen confinadas de forma estricta en el almacenamiento del *hardware* local, garantizando que la información sensible no sea expuesta a redes externas. De este modo, el Aprendizaje Federado mitiga los riesgos asociados a las brechas de seguridad informática en bases de datos centralizadas (Lee et al., 2024).

El Aprendizaje Federado se presenta como una arquitectura idónea para responder a la necesidad de resguardar la información biomédica de los usuarios desde la concepción misma del sistema protésico. Este modelo descentralizado se alinea directamente con lo que Cavoukian (citada en Danezis et al., 2014) denominó «privacidad desde el diseño» (*privacy by design*), un enfoque integral que exige que la protección de los datos sea considerada de manera ininterrumpida durante todo el ciclo de ingeniería, desde las etapas iniciales de diseño hasta la puesta en funcionamiento del sistema en producción. Al procesar las señales electromiográficas (EMG) localmente en el dispositivo y compartir únicamente los parámetros actualizados del modelo, se materializan de forma predeterminada las salvaguardias técnicas estructurales necesarias para evitar la exposición de la información sensible.

A pesar de que normativas internacionales y europeas impulsan la adopción de estas medidas desde las fases tempranas, su implementación técnica en sistemas dinámicos suele enfrentar barreras significativas. Al respecto, Danezis et al. (2014) advirtieron que quienes desarrollan los sistemas tecnológicos suelen concentrarse casi exclusivamente en satisfacer los requisitos funcionales del producto, lo que provoca que las garantías de seguridad y privacidad queden frecuentemente relegadas a un segundo plano debido al desconocimiento de las herramientas o tecnologías adecuadas para implementarlas. En este contexto, la aplicación del Aprendizaje Federado para el control mioeléctrico resulta doblemente valiosa: no solo satisface el requerimiento funcional de adaptar los movimientos a cada paciente, sino que supera las carencias del diseño tradicional de *software* al integrar la privacidad como un eje central e innegociable de la innovación tecnológica.

Por otro lado, al evaluar la aceptación de estas tecnologías desde la perspectiva del paciente, Calero Valdez y Ziefle (2018) investigaron cómo perciben los usuarios el equilibrio entre la privacidad y la utilidad al compartir datos médicos. A través de su estudio sobre sistemas de recomendación en salud, estos autores demostraron que la disposición de los pacientes a proporcionar su información depende fuertemente de las garantías de anonimización aplicadas (como la k-anonimidad o la privacidad diferencial) y, sobre todo, del destinatario final de los datos.

Para profundizar en este comportamiento, Calero Valdez y Ziefle (2018) revelaron empíricamente que los usuarios muestran un alto nivel de aceptación cuando los datos se destinan a fines científicos, pero rechazan de manera rotunda cualquier tipo de uso comercial.

Asimismo, estos investigadores descubrieron que la naturaleza de la afección juega un papel crucial: mientras que los pacientes tienen pocas reservas para compartir información sobre enfermedades físicas, existe una fuerte negativa a divulgar datos relacionados con la salud mental. En conclusión, Calero Valdez y Ziefle (2018) afirmaron que el diseño de sistemas médicos digitales debe integrar niveles de privacidad personalizables, garantizando que el usuario comprenda y mantenga el control sobre su información.

Para llevar estos requisitos de privacidad al plano tecnológico, Thapa y Camtepe (2020) explicaron que la base operativa de este nuevo paradigma radica en el Internet de las Cosas Médicas (IoMT). Según estos investigadores, la proliferación de dispositivos médicos y portátiles genera volúmenes de datos que, por su propia naturaleza, se encuentran fuertemente descentralizados, lo que exige un abordaje analítico riguroso para poder procesar la información sin exponer la identidad de los pacientes.

Para resolver este desafío de descentralización, Thapa y Camtepe (2020) detallaron que la aplicación de técnicas como el aprendizaje federado permite trasladar la capacidad de procesamiento directamente hacia los dispositivos de borde (*edge devices*), transformando cada prótesis en un nodo inteligente. De este modo, los autores destacaron que el sistema se convierte en una red colaborativa donde los modelos analíticos de Inteligencia Artificial logran una mejora global y continua aprovechando los datos locales del paciente, pero eliminando por completo la necesidad de centralizarlos o vulnerar su confidencialidad.

Desde una perspectiva de ética y responsabilidad institucional, la UNESCO (2022) subrayó que el desarrollo de este tipo de soluciones de IA sienta un precedente vital para la protección de los derechos humanos. En su marco normativo internacional, la organización estableció explícitamente que todos los actores y desarrolladores de la IA deben aplicar un enfoque innovador de "privacidad desde la etapa de concepción" (p. 22). De este modo, la UNESCO (2022) respaldó la necesidad de diseñar arquitecturas descentralizadas que incorporen principios de protección y resguardo de la información personal a lo largo de todo el ciclo de vida del sistema.

Por otro lado, Rieke et al. (2020) destacaron que, al no requerir que los usuarios compartan sus datos sin procesar, este paradigma fomenta una profunda relación de confianza. Según los investigadores, esto disminuye las barreras para la donación de datos médicos, ya

que se le garantiza al paciente que su información permanecerá en su institución de origen y que el acceso puede ser revocado en cualquier momento. Es más, Rieke et al. (2020) subrayaron que este modelo de aprendizaje distribuido facilita enormemente el cumplimiento normativo; al evitar la transferencia de información clínica sensible, el sistema se alinea de manera natural con regulaciones estrictas como el Reglamento General de Protección de Datos (RGPD), promoviendo la privacidad desde el diseño de la arquitectura y superando las vulnerabilidades de la simple anonimización de datos.

En suma, como concluyeron Lee et al. (2024), el aprendizaje federado (FL) no solo aporta novedad técnica, sino que constituye un camino responsable y sostenible para impulsar la próxima generación de prótesis inteligentes. Estos autores afirmaron que este modelo permite aprovechar las ventajas del aprendizaje profundo de forma colaborativa y comunitaria, pero respetando estrictamente la propiedad de los datos y la privacidad de cada usuario, un pilar que resulta fundamental para el desarrollo de soluciones y dispositivos médicos verdaderamente personalizados.

Tabla 2

Categorización de los algoritmos de FL según las dimensiones relevantes

Dimensión 1: Costo personalizado	Dimensión 2: Disponibilidad del Usuario	Ejemplo de Algoritmos
Tradicional	Sincrónico	FedAvg, FedProx, FedDyn, FedNTD
Personalizado	Sincrónico	Per-FedAvg, pFedMe, FedALA, GPFL, FedDBE
Tradicional	Asincrónico	FedAsync, FedSA, AsyncDrop
Personalizado	Asincrónico	PersA-FL-MAML, PersA-FL-ME, Hetero AsyncDrop

Nota. Obtenido de “Federated Learning in Open- and Closed-Loop EMG Decoding: A Privacy and Performance Perspective” (p. 6) por Malcolm et al., 2025, arXiv.

Aprendizaje Federado Tradicional

El paradigma tradicional de aprendizaje federado (TFL), representado por algoritmos como FedAvg, se enfoca en construir un único modelo global que, en promedio, funcione adecuadamente para todos los usuarios involucrados. Malcolm et al. (2025) explicaron que este enfoque resulta eficaz cuando los datos provienen de distribuciones similares, ya que al combinar información de múltiples fuentes se logra una herramienta más robusta. En contraste, los autores señalan que el entrenamiento estrictamente local —restringido a los datos de un solo individuo— adolece de una menor capacidad de generalización y obliga a que cada nuevo paciente deba entrenar su decodificador completamente desde cero.

Sin embargo, Malcolm et al. (2025) indicaron que cuando existe una marcada heterogeneidad en las distribuciones de los datos entre usuarios, el rendimiento de los métodos TFL puede verse severamente afectado, presentando problemas de lentitud en la convergencia, mayor riesgo de divergencia y resultados deficientes. Aunque algunas variantes de TFL han intentado mitigar este impacto incorporando mecanismos de adaptación, la atención de la comunidad científica se ha desplazado hacia el aprendizaje federado personalizado (PFL), debido a su mayor flexibilidad para adaptarse a las variaciones distribucionales y características individuales de cada sujeto.

Aprendizaje Federado Personalizado

A diferencia del enfoque tradicional, la personalización federada (PFL) se orienta al desarrollo de modelos específicos para cada usuario, utilizando frecuentemente el modelo global como inicialización o punto de partida. Según subrayaron Malcolm et al. (2025), esta estrategia permite obtener una mayor estabilidad frente a los cambios en la distribución de los datos. No obstante, advirtieron que su implementación conlleva desafíos adicionales, como una mayor complejidad en la configuración de hiper parámetros y una convergencia más lenta. Este enfoque resulta especialmente robusto frente a datos no independientes e idénticamente distribuidos (*non-IID*). Por ello, la literatura reciente documenta un aumento sostenido de algoritmos orientados a la personalización (tales como Per-FedAvg, pFedMe, APFL, FedALA, Fedcp, FedDBE y GPFL), aunque los autores destacaron que la mayoría de estas arquitecturas han sido validadas principalmente en conjuntos de datos de imágenes estandarizados, como CIFAR-100.

Aprendizaje Federado Sincrónico

El Aprendizaje Federado Sincrónico asume como condición operativa que la totalidad de los dispositivos cliente seleccionados se encuentren activos, disponibles y con conectividad estable para participar de forma simultánea en cada ronda de actualización global. Esta presunción estructural, si bien simplifica la arquitectura de los algoritmos de FL más extendidos, introduce severas restricciones al trasladarse a aplicaciones e infraestructuras del mundo real, tal como lo indicaron Malcolm et al. (2025).

Aunque su naturaleza matemática resulta conveniente para la validación en simulaciones controladas, este modo de ejecución pierde viabilidad en entornos experimentales complejos, como los sistemas de interfaz neuronal de lazo cerrado, donde la variabilidad del *hardware* y los tiempos de fatiga de los usuarios humanos impiden una coordinación simultánea estricta (Malcolm et al., 2025).

Adicionalmente, los entornos síncronos presentan una alta vulnerabilidad al fenómeno de los dispositivos rezagados (*stragglers*), definidos como aquellos nodos que experimentan demoras en el procesamiento local de sus gradientes debido a restricciones de *hardware* o conectividad. La presencia de estos nodos lentos no sólo ralentiza el progreso de la ronda global, sino que puede llegar a bloquear la actualización del servidor en caso de desconexiones abruptas. Pese a estas fricciones operativas, el FL síncrono mantiene una vigencia significativa en estudios simulados de lazo abierto, donde las restricciones logísticas reales no interfieren con la evaluación matemática de los modelos (Malcolm et al., 2025).

Aprendizaje Federado Asincrónico

Según Malcolm et al. (2025), el Aprendizaje Federado Asincrónico introdujo un esquema flexible de entrenamiento distribuido al facultar a los dispositivos participantes para interactuar, consultar y actualizar los parámetros del modelo global de manera no simultánea e independiente del estado de los demás nodos. Esta independencia operativa constituyó una ventaja frente a las arquitecturas síncronas, puesto que mitiga la dependencia hacia la disponibilidad continua de la red de clientes y neutraliza el impacto negativo de los dispositivos lentos o con conexiones intermitentes.

No obstante, esta flexibilidad operativa introduce complejidades analíticas asociadas al fenómeno de las actualizaciones obsoletas (*stale updates*), donde los gradientes calculados sobre versiones desactualizadas del modelo global pueden inducir a inestabilidades y penalizar la convergencia del entrenamiento. Asimismo, aquellos nodos que posean capacidades de procesamiento superiores o conexiones más estables pueden sesgar de forma desproporcionada el modelo global hacia sus datos locales (Malcolm et al., 2025).

A pesar de estas dificultades, el flujo intermitente y heterogéneo de actualizaciones locales característico de los entornos asincrónicos opera frecuentemente como un mecanismo natural de regularización, aportando robustez y capacidad de generalización al modelo colectivo (Malcolm et al., 2025). Debido a estos atributos adaptativos, los esquemas asincrónicos se perfilan como las alternativas de mayor viabilidad para implementaciones clínicas reales en la vida diaria, siempre que se garantice la participación sostenida de al menos un subconjunto representativo de usuarios.

Recolección de Datos

Definiciones principales

Definición de variables

Para el presente estudio, se identificó la variable independiente, la cual es la implementación de técnicas de *Deep Learning* y Aprendizaje Federado en el procesamiento de señales electromiográficas (EMG) para prótesis mioeléctricas. Luego, se detectaron las variables dependientes como el nivel de personalización alcanzado en el control de la prótesis, el nivel de preservación de la privacidad de los datos sensibles del usuario, la aceptación clínica y percepción ética del uso de estas tecnologías, la viabilidad técnica y grado de accesibilidad de este tipo de dispositivos. Estas variables se ejecutaron a través de un formulario estructurado con preguntas cerradas, abiertas y de selección múltiple, dirigido a distintos perfiles profesionales y técnicos.

Determinación de población

La población objetivo se conformó por profesionales y especialistas vinculados al desarrollo, evaluación y aplicación de tecnologías biomédicas, incluyendo médicos (especialmente fisiatras, neurólogos, traumatólogos y rehabilitadores), ingenieros/as biomédicos, ingenieros/as en informática con conocimientos de IA, investigadores en ciencias de la salud y/o ciencias de la computación, profesionales en inteligencia artificial, ciencia de datos o ingeniería en sistemas, usuarios y diseñadores de prótesis mioeléctricas y estudiantes avanzados en carreras afines con formación en IA aplicada a salud o robótica médica. Esta población fue seleccionada por su potencial para aportar una mirada informada sobre los aspectos técnicos, éticos y clínicos del uso de aprendizaje profundo en el diseño de prótesis inteligentes.

Técnica utilizada

Se empleó la técnica de encuesta estructurada autoadministrada mediante un formulario digital en Google Form, el cual fue distribuido por canales institucionales, redes profesionales y contacto directo con referentes del área. Esta técnica permitió recolectar información

cualitativa y cuantitativa de manera ágil, respetando la diversidad geográfica y disciplinar de los participantes. El instrumento incluyó preguntas cerradas de opción múltiple, de escala de valoración tipo Likert y abiertas para comentarios o aportes específicos.

El diseño del cuestionario respondió al objetivo de explorar la viabilidad, aceptación y desafíos asociados al uso de técnicas de *Deep Learning* y *Federated Learning* en prótesis mioeléctricas personalizadas y respetuosas de la privacidad del usuario tanto desde la perspectiva técnica como desde la perspectiva médica.

Además, en lo respectivo al material bibliográfico, Hernández-Sampieri et al. (2014) explicaron que la revisión de registros históricos y documentos admite una técnica de análisis mixta. Según detallaron estos mismos autores, estos registros permiten codificar e interpretar de manera simultánea tanto la presencia numérica de variables categóricas concretas para la fase cuantitativa, como el significado profundo del texto para la vertiente cualitativa. Esta dualidad fue esencial para poder realizar el análisis y la comparación con los datos que se recaudaron en el formulario de la población objetivo.

Finalmente, se aplicó la técnica de entrevista cualitativa a un especialista en Inteligencia Artificial y Ciberseguridad. Este instrumento se utilizó para recolectar testimonios y datos técnicos profundos sobre las limitaciones de *hardware*, la latencia en dispositivos periféricos y las estrategias de seguridad informática necesarias para implementar modelos federados en entornos no controlados.


Datos obtenidos de la encuesta realizada a la población objetivo

Los datos cuantitativos primarios se obtuvieron mediante un formulario que contó con 102 respuestas válidas de profesionales vinculados a la tecnología, la biomedicina y la investigación aplicada. Esta conformación representa una "muestra de expertos", un abordaje idóneo donde la pertinencia y el nivel de profundidad de la información prevalecen sobre la generalización estadística poblacional (Hernández-Sampieri et al., 2014). La distribución de la muestra evidencia un carácter interdisciplinario: la mayoría de los participantes pertenece al área de Sistemas e Informática (55,8%), seguida por Medicina (22,5%), Inteligencia Artificial (8,8%), *Data Science* (2,9%) y Kinesiología/Fisiatría (2,9%), con participaciones

complementarias en Biomedicina y Ciberseguridad (véase Figura 8).

Figura 8

Distribución de áreas profesionales de los participantes



Nota. Obtenido de la encuesta realizada a la población objetivo.


Este resultado refleja una muestra interdisciplinaria, en la que convergen tanto perfiles técnicos como clínicos, condición necesaria para el análisis integral del desarrollo de prótesis mioeléctricas basadas en Aprendizaje Profundo y Aprendizaje Federado.

En cuanto a la trayectoria profesional, el 37,3% de los encuestados posee más de 10 años de experiencia, seguido por un 27,5% con entre 6 y 10 años, un 19,6% con 3 a 5 años y un 15,7% con 0 a 2 años. Esto demuestra que la mayoría de los participantes cuenta con una base sólida de conocimiento en sus disciplinas, garantizando la validez técnica de las percepciones registradas.

El 86,5% de los participantes afirmó que el uso de *Deep Learning* puede mejorar significativamente la personalización de las prótesis mioeléctricas, especialmente en la imitación de movimientos naturales de brazos y piernas. Como vemos en la Figura 9, las principales ventajas identificadas fueron: Mayor precisión en el reconocimiento de movimientos musculares (70,3%); Entrenamiento continuo y personalizado (54,1%); Mejora en la experiencia de uso (45,9%); Capacidad de adaptación a cambios fisiológicos del usuario (37,8%) y Menores necesidades de calibraciones frecuentes (37,8%).

Figura 9

Ventajas de la aplicación de Deep Learning y Aprendizaje Federado




Nota. Obtenido de la encuesta realizada a la población objetivo.

Respecto a la factibilidad técnica, la mayoría la calificó como media o alta según se puede ver en la Figura 10, lo que sugiere que los encuestados perciben la tecnología como viable, aunque todavía dependiente de mejoras en *hardware* y optimización de modelos.

Figura 10

Gráfico de barras con datos obtenidos de factibilidad de aplicación de DL




Nota. Obtenido de la encuesta realizada a la población objetivo.

Sin embargo, en la Figura 11 podemos ver que también se señalaron desafíos que pueden impedir que la Inteligencia Artificial personalizada sea implementada actualmente en prótesis mioeléctricas, las más votadas fueron: Limitaciones de *hardware* (32,4%); Complejidad en el entrenamiento y ajuste del modelo (27,0%); Escasa disponibilidad de *datasets* de señales EMG (20,3%) y Recolección y procesamiento de datos en tiempo real (16,2%).

Figura 11


Desafíos técnicos para implementar IA en prótesis mioeléctricas



El 62,2% de los participantes considera viable la aplicación del Aprendizaje Federado (FL) en prótesis mioeléctricas, mientras que un 33,8% se mostró indeciso y un 4,1% lo considera no viable como indica la Figura 12, aunque un 35,5% aclaró que la tecnología aún requiere mayor madurez y estandarización antes de su adopción clínica. Los participantes coincidieron en que el FL favorece la privacidad, ya que permite entrenar modelos sin compartir datos crudos, preservando la información biomédica sensible del paciente.

Figura 12

Gráfico de viabilidad técnica de aplicar FL para entrenar modelos de IA




El análisis sugiere que el FL es percibido como un complemento ético y técnico viable para el desarrollo de prótesis inteligentes ya que optaron por esta opción el 80,3% de los

encuestados, aunque todavía requiere validación experimental y estandarización de protocolos antes de su adopción clínica, ya que existen medidas necesarias para proteger la privacidad de los usuarios, como vemos en la Figura 13, entre las más elegidas están: Consentimiento claro y específico del usuario (75,0%); Encriptación de datos durante todo el proceso (69,7%) y Acceso restringido y monitoreado a los datos (53,9%).


Figura 13

Medidas necesarias para proteger la privacidad del usuario



Nota. Obtenido de la encuesta realizada a la población objetivo.

Los encuestados expresaron alta conciencia sobre los riesgos éticos de la inteligencia artificial aplicada a dispositivos médicos, donde el 56,6% lo consideraron un riesgo medio/alto. Entre los principales datos vulnerables del usuario que vemos en la Figura 14, se consideraron más sensibles: Datos biométricos (67,9%); Imágenes o grabaciones personales (50,0%); Señales EMG de los músculos (46,4%) e Historial médico (46,4%).

Figura 14*Datos sensibles al usar Inteligencia Artificial*

Nota. Obtenido de la encuesta realizada a la población objetivo.

Asimismo, del 80,3% de la población que considera ético el uso de datos del paciente según indica la Figura 15, el 75,0% coincidió en que el consentimiento informado y la encriptación de datos son medidas esenciales para la protección de la privacidad y un 69,7% está de acuerdo con la encriptación de datos durante todo el proceso para que no sean vulnerados.


Figura 15*Gráfico sobre consideraciones éticas en el uso de datos de pacientes*

Nota. Datos obtenidos de la encuesta realizada a la población objetivo que indica si se considera ético utilizar datos del paciente para entrenar modelos de IA.

En el plano clínico, el 50,0% de los encuestados opinó que el personal médico aceptaría el uso de prótesis potenciadas con inteligencia artificial si existieran evidencias de eficacia y seguridad. No obstante, entre los factores indicados en la Figura 16, señalaron los más importantes para su adopción: Evidencia científica sólida (39,3%); Mejora funcional respecto a prótesis tradicionales (32,1%) y Bajo costo para el paciente (17,9%).


Figura 16

Factores determinantes para la adopción clínica




Nota. Obtenido de la encuesta realizada a la población objetivo.

En cuanto a la accesibilidad, el 41,3% consideró que estas prótesis no serían económicamente accesibles para la mayoría de los pacientes sin subsidios estatales o programas públicos de inclusión tecnológica. Además, consideraron que los factores que más podrían dificultar la adopción según la Figura 17 son: Alto costo económico (82,9%); Falta de profesionales capacitados (51,3%) y Prejuicios o desconocimientos (50,0%)

Figura 17*Factores que dificultan la adopción clínica*

Nota. Obtenido de la encuesta realizada a la población objetivo.

Finalmente, la percepción global sobre el potencial de combinar Aprendizaje Profundo con Aprendizaje Federado obtuvo un promedio de 4,1 sobre 5 como podemos ver en la Figura 18. Esta valoración evidencia optimismo moderado entre los profesionales, quienes reconocen el valor de estas tecnologías para personalizar la respuesta mioeléctrica, reducir errores en la decodificación de señales y resguardar la privacidad del usuario.

Figura 18*Ponderación de potencial de Deep Learning y Aprendizaje Federado*

Nota. Obtenido de la encuesta realizada a la población objetivo.

Datos obtenidos de la entrevista realizada

Para profundizar en la viabilidad técnica y las barreras de implementación del modelo propuesto, se realizó una entrevista en profundidad a un especialista en Inteligencia Artificial

y Ciberseguridad. Los hallazgos cualitativos corroboraron las tendencias observadas en la encuesta cuantitativa —donde el 32,4% de los profesionales señaló las limitaciones de *hardware* como el principal desafío técnico— y aportaron perspectivas clave sobre la arquitectura del sistema.

Al ser consultado sobre los cuellos de botella para ejecutar modelos de IA directamente en dispositivos periféricos pequeños y de bajo consumo, el especialista advirtió que estos equipos, con características propias del Internet de las Cosas (IoT), carecen de la capacidad de cálculo necesaria para un procesamiento neuronal integrado. Si bien esta limitación suele derivar en la necesidad de ejecutar el módulo de forma remota en un servidor (*backend*) con mayor potencia, el experto subrayó una restricción operativa insalvable: "una prótesis debería poder ejecutarse siempre independientemente de la calidad de conexión existente en ese momento". En otras palabras, la falta de acceso a internet no puede interrumpir el funcionamiento del dispositivo biónico.

Para superar esta barrera de conectividad y, al mismo tiempo, contemplar el consumo crítico de batería, el entrevistado recomendó la adopción de "modelos híbridos". Este enfoque permitiría que el dispositivo IoT disponga de una autonomía prolongada, operando de manera local mediante el almacenamiento en el propio dispositivo de los parámetros necesarios para funcionar durante las desconexiones (de forma análoga a los sistemas de validación de saldo *offline* en el transporte público).

En cuanto al equilibrio entre la baja latencia y la exigencia computacional de los modelos, el especialista propuso una estrategia de optimización basada en el precálculo de movimientos. Esta técnica consiste en almacenar localmente en la prótesis las combinaciones motrices más probables, funcionando como un árbol de decisión que restringe las opciones lógicas según la posición actual de la extremidad. Si bien este enfoque garantiza una respuesta cuasi-inmediata, presenta como desventaja la necesidad de actualizar la memoria de todos los dispositivos de manera simultánea ante cada mejora del modelo.

Respecto al desafío que representa la alta variabilidad fisiológica y la escasez de bases de datos estandarizadas —una barrera técnica advertida por el 20,3% de los encuestados—, el entrevistado recomendó la creación de emuladores para realizar pruebas controladas y la

proyección de valores futuros respaldados por evidencia científica. Asimismo, sugirió adoptar un enfoque *Beyond the Lab* (más allá del laboratorio), consistente en la recolección iterativa de datos de uso experimental para robustecer el producto en condiciones reales.

Al evaluar las implicancias del Aprendizaje Federado, el experto ratificó que sus principales ventajas radican en la protección de la privacidad y el aprendizaje en tiempo real. Sin embargo, advirtió sobre complicaciones operativas significativas: además de la complejidad inherente a la sincronización de parámetros entre múltiples dispositivos, la arquitectura exige sobredimensionar la capacidad de cómputo de la prótesis exclusivamente para la etapa de entrenamiento. En consecuencia, asumiendo que los patrones de movimiento del paciente tienden a estabilizarse, la mayor parte de esta capacidad de *hardware* quedaría ociosa durante la fase de ejecución regular.

Finalmente, en materia de seguridad de la información biomédica, el especialista delineó medidas de protección indispensables a nivel de infraestructura. Estas incluyen la segregación rigurosa entre Datos de Identificación Personal Sensibles (SPII) y Datos Personales Estándar (PII), la radicación de bases de datos en jurisdicciones internacionalmente autorizadas y la implementación de un cifrado de múltiples capas (protección tipo "cebolla") para mitigar cualquier vulnerabilidad o fuga innecesaria de información.

Análisis de Datos

Técnica utilizada

A continuación, se presenta el análisis de las respuestas de los 102 encuestados empleando una estrategia mixta. Para la evaluación cuantitativa de los datos, se utilizó estadística descriptiva mediante distribuciones de frecuencias, porcentajes y medidas de tendencia central (Hernández-Sampieri et al., 2014).

Respecto a la calidad del instrumento, la confiabilidad metodológica se determinó evaluando las medidas de consistencia interna, mientras que la validez de contenido se aseguró al comprobar que la medición representara adecuadamente los conceptos de interés —en este caso, los constructos de personalización, factibilidad técnica y privacidad— (Hernández-Sampieri et al., 2014). Finalmente, como complemento de la vertiente cualitativa, se incluyeron fragmentos y testimonios en lenguaje natural de la entrevista realizada al experto en IA y ciberseguridad, con el fin de enriquecer el reporte de resultados (Hernández-Sampieri et al., 2014).

Análisis detallado

Perfil muestral y validez de contenido. La muestra es interdisciplinaria, ya que cuenta con los perfiles de Sistemas/Informática (55,8%), Medicina (22,5%), IA (8,8%), *Data Science* (2,9%), Kinesiología/Fisiatría (2,9%), Biomedicina (2,0%) y menciones marginales (Odontología, Obstetricia, Ciberseguridad). Este equilibrio técnico-clínico es pertinente para el problema planteado (control mioeléctrico personalizado con DL y FL) y fortalece la validez de contenido de las percepciones recogidas. Asimismo, el 37,3% de los encuestados posee más de 10 años de experiencia y el 27,5% tiene entre 6 y 10 años; por tanto, el 64,8% reporta una trayectoria de mucha experiencia, lo que aumenta sustancialmente la credibilidad de los juicios emitidos. Para respaldar esta decisión, Hernández-Sampieri et al. (2014) recomendaron recurrir a este tipo de muestras dirigidas de expertos, dado que su pertinencia y profundo nivel de conocimiento resultan idóneos para generar información válida en estudios especializados.

Deep Learning (DL), utilidad percibida y factibilidad. En cuanto a la utilidad e impacto, el 86,5% de los participantes considera que el DL mejora significativamente la personalización

y la naturalidad del movimiento. En una lectura analítica, la concentración de respuestas en la "precisión" y el "aprendizaje continuo" indica que los participantes no sólo asocian el DL con la exactitud, sino con la adaptabilidad (constructo clave de la personalización). La coincidencia entre la "adaptación fisiológica" y las "menores recalibraciones" sugiere una representación mental convergente del beneficio: sistemas que se ajustan al usuario y reducen la fricción operativa.

Por otro lado, al evaluar la factibilidad técnica mediante una escala Likert, la mediana se ubicó en un nivel medio-alto, con matices referidos al *hardware* y la optimización. Metodológicamente, Hernández-Sampieri et al. (2014) explicaron que los enfoques descriptivos son herramientas muy útiles para medir e interpretar con precisión estos componentes y dimensiones de un fenómeno. Tomando como base este principio descriptivo avalado por los autores, se infiere que la combinación de una alta utilidad percibida junto con una factibilidad condicionada conforma un hallazgo robusto, el cual respalda la hipótesis de que la viabilidad técnica real del sistema depende críticamente de la infraestructura de *hardware* periférico.

Barreras y riesgos técnicos (IA en prótesis). Interpretación: Las barreras se alinean con el estado del arte: el cuello de botella no es conceptual, sino ingenieril (cómputo embebido, datos EMG curados y latencia). En términos de explicación, estas categorías actúan como variables intervinientes que moderan el pasaje de utilidad percibida a adopción efectiva. Al respecto, la perspectiva cualitativa del especialista en Inteligencia Artificial entrevistado para este estudio confirma que las restricciones de *hardware* obligan a replantear la arquitectura:

Los dispositivos pequeños generalmente no poseen gran capacidad de cálculo para poder ejecutar un modelo de IA integrado en un *device* de características IoT. Esto trae como derivado la necesidad de ejecutar el módulo de forma remota en un *backend* [...] El problema de este último *approach* es que una prótesis debería poder ejecutarse siempre independientemente de la calidad de conexión [...] En estos casos se suele optar por modelos híbridos que permitan al dispositivo IoT tener autonomía prolongada. (L. Valido, comunicación personal, 9 de junio de 2026)

Para compensar esta limitante computacional y resolver el problema de la latencia sin depender constantemente de internet (como ejemplifica el experto entrevistado con el

funcionamiento autónomo de la tarjeta SUBE local), la alternativa técnica radica en la anticipación: "lo que se puede hacer es pre calcular los movimientos más comunes y factibles que una persona realiza y guardarla localmente en cada *device* [...] La implementación termina siendo un mini árbol de decisión que permite limitar la cantidad de opciones" (L. Valido, comunicación personal, 9 de junio de 2026).

Asimismo, frente al problema de la escasez de datos EMG curados y la alta variabilidad fisiológica, L. Valido (comunicación personal, 9 de junio de 2026) aporta que no es un obstáculo definitivo para las primeras etapas, ya que "podes generar algún tipo de emulador-simulador para hacer cualquier tipo de pruebas", además de entrenar los modelos con base en material científico para lograr un pronóstico de valores futuros.

En cuanto a la viabilidad del Aprendizaje Federado (FL), el 62,2% de los encuestados lo consideró viable, el 33,8% se mostró indeciso y apenas un 4,1% lo evaluó como no viable. Desde una posición ética-técnica, el 80,3% percibe al FL como un complemento adecuado para las prótesis inteligentes.

Esta dicotomía es explicada de manera precisa por el especialista en IA, quien identificó como ventajas indiscutibles del modelo descentralizado "la privacidad y el aprendizaje *real time*", pero advierte sobre complicaciones técnicas e ingenieriles críticas que fundamentan dicha incertidumbre:

[Existe] Complejidad en la sincronización de dispositivos (¿lo que aprendes en el *device* 1 cómo llevas ese aprendizaje al *device* 2?) y capacidad de cómputo ocioso la mayor parte del tiempo. Se debe sobre dimensionar la capacidad de cómputo del *device* solamente para la etapa de aprendizaje, posterior solo ejecuta lo aprendido. (L. Valido, comunicación personal, 9 de junio de 2026)

Riesgos éticos y datos sensibles. Interpretación: Se reconoce a la señal EMG como dato sensible, resultado relevante para el diseño de protocolos FL (por ejemplo: agregación segura, DP, control de metadatos). La conciencia de riesgo funciona como *driver* de aceptación condicionada: habilita el uso si se garantizan las medidas de resguardo, como las que indicó L. Valido (comunicación personal, 9 de junio de 2026): "Las medidas de seguridad indispensables

son: utilizar bases de datos en países autorizados, diferenciar datos SPII de datos PII y protección tipo cebolla de los datos a fin de evitar *leak* innecesarios”.

Aceptación clínica y criterios de adopción. Aceptación clínica potencial: 50,0% la ve factible si hay evidencia de eficacia y seguridad. Criterios de adopción: evidencia científica sólida (39,3%) y mejora funcional frente a prótesis tradicionales (32,1%). Lectura analítica: El umbral de adopción depende de pruebas clínicas y beneficio funcional medible. En términos de explicación causal, la evidencia opera como variable mediadora entre factibilidad percibida e implementación clínica.

Accesibilidad y brecha de adopción. Respecto a la accesibilidad económica, el 41,3% de los encuestados cree que la prótesis no sería accesible sin subsidios o programas públicos. Asimismo, se identificaron como principales obstáculos el alto costo (82,9%), el déficit de profesionales capacitados (51,3%) y los prejuicios o el desconocimiento (50,0%). Desde una interpretación analítica, se deduce que la barrera económica es dominante, mientras que el capital humano especializado y la alfabetización tecnológica representan cuellos de botella adicionales. Metodológicamente, Hernández-Sampieri et al. (2014) advirtieron que, en la estadística descriptiva, los resultados numéricos de un estudio siempre deben interpretarse en función de su contexto. Tomando como base esta directriz, se infiere que estas barreras son precisamente las condiciones contextuales reales que restringen y limitan la adopción masiva de la tecnología en el mercado.

Síntesis integradora (triangulación interna). La convergencia de tres bloques los cuales son la alta utilidad de DL (86,5%), viabilidad percibida de FL (62,2%) y exigencia de proteger los datos personales ($\geq 69,7\%$ cifrado; 75,0% consentimiento) apoya la proposición central del trabajo: DL + FL como vía técnicamente plausible y éticamente aceptable para personalización de control mioeléctrico resguardando la confidencialidad. La disonancia identificada (hardware, datos EMG, tiempo real, costos) no invalida la propuesta, pero delimita condiciones de implementación (computación embebida eficiente, curación/estandarización de datasets, protocolos clínicos y financiamiento).

Para el cierre del estudio, la investigación se apoyó en los métodos de análisis descriptivo y comparativo con el propósito de determinar si la hipótesis planteada era apoyada o refutada por los datos observados (Hernández-Sampieri et al., 2014). Siguiendo este principio empírico, se concluye que los datos recolectados respaldan sólidamente la hipótesis operacional de que el *Deep Learning* (DL) mejora la personalización del control mioeléctrico y que el *Federated Learning* (FL) es percibido como el mecanismo idóneo para proteger la privacidad en el entrenamiento distribuido.

Finalmente, como aporte directo de esta investigación, se determina que la implementación clínica de este ecosistema depende de cuatro palancas clave: la optimización en *hardware* embebido, la estandarización de *datasets* de señales EMG, el desarrollo de protocolos de seguridad y consentimiento y la generación de evidencia clínica que demuestre tanto la mejora funcional como la costo-efectividad.

Nota: La transcripción completa de la entrevista cualitativa realizada al especialista en Inteligencia Artificial, así como la guía de preguntas utilizada, se encuentran disponibles en el Anexo II de este documento.

Informe final de resultados

Los resultados obtenidos en la recolección de datos (tanto del relevamiento bibliográfico, como del cuestionario aplicado a profesionales y la entrevista cualitativa al experto en IA) evidenciaron un consenso sólido sobre el potencial del Aprendizaje Profundo y el Aprendizaje Federado para mejorar la personalización y preservar la privacidad de los datos del usuario en prótesis mioeléctricas.

El 86,5% de los encuestados afirmó que el uso de DL mejoraría significativamente la personalización y el 62,2% consideró viable el uso de FL como método de entrenamiento colaborativo sin exposición de datos sensibles. Asimismo, la literatura revisada respaldó empíricamente estas percepciones: los modelos basados en redes neuronales profundas y meta-aprendizaje federado (Per-FedAvg, FedProx) han demostrado mayor precisión, adaptabilidad y robustez en señales EMG manteniendo la confidencialidad de los datos del usuario mediante entrenamiento local y agregación segura.

Contraste con la hipótesis de investigación. La hipótesis de este trabajo sostiene que los sistemas de control para prótesis mioeléctricas que integran técnicas de *Deep Learning* Federado muestran una interpretación más precisa y personalizada de las señales electromiográficas, al tiempo que preservan la privacidad de los datos del usuario. A partir del análisis descriptivo y comparativo de los datos recolectados, se verificó la veracidad de la hipótesis, ya que los participantes reconocieron la capacidad del DL para ajustarse a la fisiología individual del usuario y reducir las calibraciones manuales al mismo tiempo que el FL fue percibido como una herramienta ética y viable para entrenar modelos sin comprometer la privacidad de los datos del usuario.

Los principales riesgos identificados en la encuesta (limitaciones de *hardware*, *datasets* limitados y costos) no refutaron la hipótesis, sino que delimitaron las condiciones prácticas de implementación. Es aquí donde la indagación cualitativa aportó un sentido de entendimiento profundo para dar solución a estas barreras. Como señaló el especialista en Inteligencia Artificial entrevistado L. Valido (comunicación personal, 9 de junio de 2026), la limitante de *hardware* en la periferia obliga a evitar depender exclusivamente de la nube, ya que "una

prótesis debería poder ejecutarse siempre independientemente de la calidad de conexión". Para ello, el experto advirtió que la viabilidad técnica reside en utilizar "modelos híbridos que permitan al dispositivo IoT tener autonomía prolongada" (ejemplificando con el funcionamiento local de la tarjeta SUBE), sumado a estrategias de *software* que reduzcan el peso computacional, tales como "pre calcular los movimientos más comunes" mediante un "mini árbol de decisión que permite limitar la cantidad de opciones".

Aportes teóricos y prácticos. Desde el plano teórico, esta investigación contribuyó a integrar la literatura de Aprendizaje Profundo y Federado con la problemática específica de las prótesis mioeléctricas, proponiendo un enfoque interdisciplinario que vincula ingeniería biomédica, inteligencia artificial y ética de datos. En el plano práctico, los resultados sugirieron que una arquitectura combinada DL+FL mejora la decodificación de señales EMG mediante aprendizaje continuo (lo que el experto denomina "aprendizaje *real time*"), preserva la confidencialidad del usuario gracias al entrenamiento distribuido y potencia la viabilidad clínica y social de prótesis inteligentes personalizadas.

Estos hallazgos constituyeron una base empírica para futuras líneas de investigación, favoreciendo el diseño de sistemas que combinen precisión biomecánica, escalabilidad y seguridad de datos. En conjunto, los datos cuantitativos, cualitativos y bibliográficos confirmaron la validez de la hipótesis planteada: el Aprendizaje Profundo y el Aprendizaje Federado constituyen enfoques complementarios capaces de incrementar la personalización funcional de las prótesis mioeléctricas, al tiempo que resguardan la privacidad del usuario.

El desarrollo futuro debe orientarse a superar barreras técnicas y económicas, a optimizar modelos para *hardware* embebido y a establecer estándares clínicos y éticos que posibiliten su implementación segura en entornos reales.

Conclusiones

La presente investigación ha permitido validar la hipótesis planteada: la integración del Aprendizaje Profundo (*Deep Learning*) y el Aprendizaje Federado (*Federated Learning*) en prótesis mioeléctricas logra una interpretación más precisa y personalizada de las señales electromiográficas (EMG), preservando a su vez la privacidad de los datos del usuario.

Esta confirmación se sustenta en una sólida triangulación metodológica que articula tres pilares de evidencia. En primer lugar, la revisión del estado del arte demuestra teóricamente que las arquitecturas neuronales profundas superan a los métodos convencionales, logrando incrementar la tasa de cumplimiento de movimientos motrices hasta un 94,4% (Zbinden et al., 2024). Simultáneamente, los resultados respaldan que enfoques federados como FedAssist (Lee et al., 2024) consiguen un riesgo empírico de exposición de datos nulo (0,0) (Malcolm et al., 2025), resolviendo el dilema entre optimización y confidencialidad.

En segundo lugar, estos hallazgos teóricos convergen con la evidencia cuantitativa recolectada en el trabajo de campo. La comunidad de profesionales consultada valida de manera mayoritaria que el *Deep Learning* es el motor idóneo para la personalización funcional, avalando a su vez al Aprendizaje Federado como el mecanismo colaborativo seguro para el manejo de información del usuario. Lejos de refutar la viabilidad de este modelo, los principales riesgos identificados —como las restricciones de *hardware* periférico y la escasez de *datasets* estandarizados— cumplieron la función de delimitar las condiciones prácticas para su implementación.

Es aquí donde el tercer pilar, la evidencia cualitativa, traza soluciones aplicables. Queda establecido que los cuellos de botella de latencia y procesamiento pueden superarse mediante arquitecturas híbridas y lógicas de decisión precalculadas localmente, garantizando la autonomía del dispositivo sin depender de una conexión constante a la nube.

Desde una perspectiva académica, este trabajo contribuye a integrar la literatura teórica de la inteligencia artificial y la ingeniería biomédica con la ética de los datos. A nivel práctico, postula que una arquitectura combinada (DL + FL) no solo optimiza la decodificación de señales mediante un aprendizaje continuo, sino que fomenta la viabilidad clínica al asegurar la

privacidad desde el diseño.

En conclusión, el tránsito desde sistemas de control genéricos hacia prótesis impulsadas por el Aprendizaje Profundo Federado representa un avance que trasciende la mera mejora funcional. Al confinar el procesamiento de datos de forma local en el dispositivo periférico, la bioingeniería se erige como un ecosistema seguro y ético. Esta tecnología no solo busca restituir la movilidad física a través de extremidades biónicas más precisas, sino que constituye un acto de recuperación de la autonomía integral del paciente, respetando su individualidad y garantizando su absoluta soberanía sobre su propia información biomédica.

Limitaciones del estudio

A pesar de la solidez de los resultados, se reconocen las siguientes limitaciones del estudio:

En primer lugar, es importante delimitar el alcance metodológico bajo el cual se conceptualizó este estudio. La validación de la propuesta se fundamentó rigurosamente en el análisis de percepciones de expertos y en una exhaustiva revisión documental, lo que permitió consolidar una base teórica y conceptual sólida. No obstante, el diseño actual no contempló una fase de validación experimental en tiempo real con sujetos amputados. Esta particularidad sitúa los hallazgos en un plano predominantemente analítico y de simulación, dejando la interacción directa con usuarios finales y la evaluación de la experiencia de uso en entornos reales como un paso subsiguiente y necesario para futuras etapas del proyecto.

Por otro lado, la viabilidad técnica y la aplicabilidad de los resultados se encuentran estrechamente condicionadas por barreras de infraestructura tecnológica actuales. Específicamente, la implementación efectiva del sistema depende de la disponibilidad y el acceso a *hardware* embebido de bajo consumo que posea la capacidad de cómputo necesaria para procesar redes neuronales complejas en la periferia (*edge computing*). Dado que los dispositivos comerciales actuales a menudo presentan un compromiso entre la eficiencia energética y la potencia de procesamiento, el despliegue del modelo queda sujeto a los avances y a la democratización de plataformas de *hardware* más eficientes y optimizadas para la inteligencia artificial.

Finalmente, el estudio enfrenta un desafío significativo en términos de estandarización debido a las características del ecosistema de datos disponible. La escasez de *datasets* públicos y masivos de señales electromiográficas (EMG) restringe notablemente la variabilidad de los datos de entrenamiento y prueba utilizados. Esta falta de homogeneidad y volumen en los registros biomédicos limita la capacidad de generalizar los hallazgos obtenidos a un espectro clínico más amplio, especialmente al considerar la diversidad de patologías, niveles de amputación y particularidades fisiológicas que presentan las distintas afecciones de miembro superior.

Líneas Futuras de Investigación

Si bien los resultados obtenidos mediante la recolección de datos empíricos y revisión documental evidencian una aceptación y factibilidad teórica del modelo propuesto, resulta necesario avanzar hacia una fase experimental controlada, en la que los algoritmos de DL y FL se apliquen en entornos clínicos reales con usuarios de prótesis.

Esta validación permitiría medir indicadores objetivos como precisión electromiográfica, latencia de respuesta, consumo energético, robustez intersujeto y tasa de error activo, comparando el rendimiento del sistema frente a modelos tradicionales de control. La obtención de métricas cuantitativas respaldadas por ensayos clínicos contribuiría a consolidar la transferencia tecnológica desde el laboratorio hacia la práctica médica, fortaleciendo la confiabilidad y adopción del modelo propuesto.

Una línea de trabajo clave será la exploración de arquitecturas híbridas, que integren modelos CNN, RNN y GAN con enfoques de aprendizaje por transferencia y aprendizaje reforzado, buscando optimizar la decodificación de señales EMG bajo condiciones dinámicas.

Asimismo, se propone investigar el potencial de redes FitDNN (Folded-in-Time Deep Neural Networks), que permiten emular redes profundas utilizando menor *hardware*, lo cual podría resolver uno de los principales desafíos técnicos señalados: la limitación de recursos computacionales en dispositivos periféricos como prótesis.

Esta línea apunta a mejorar la eficiencia computacional, la capacidad de generalización y la estabilidad interdominio, facilitando el despliegue de sistemas inteligentes más ligeros, rápidos y autónomos. Los resultados demostraron una percepción positiva sobre el Aprendizaje Federado como mecanismo de preservación de privacidad; sin embargo, la literatura aún presenta escasas implementaciones en entornos biomédicos distribuidos.

Por ello, se plantea como línea futura la creación de redes federadas multicéntricas, donde distintas instituciones de salud o laboratorios puedan entrenar modelos colaborativos sin intercambiar datos sensibles. Esto permitiría aumentar el volumen y diversidad de datos de

entrenamiento, mejorando la precisión y generalización de los modelos sin comprometer la confidencialidad de los pacientes.

A su vez, se recomienda explorar versiones personalizadas y asincrónicas del FL, más adecuadas para entornos con conectividad intermitente o *hardware* heterogéneo, optimizando la eficiencia y escalabilidad del aprendizaje distribuido.

Aunque el FL ofrece garantías robustas de protección, las nuevas normativas internacionales en bioética digital demandan estrategias complementarias para mitigar riesgos emergentes. En este sentido, futuras investigaciones deberían incorporar mecanismos de privacidad diferencial, encriptación homomórfica y auditorías de equidad algorítmica, asegurando que los modelos de IA biomédica no sólo sean precisos, sino también transparentes, auditables y equitativos.

También se propone el desarrollo de protocolos éticos estandarizados que regulen el consentimiento informado digital, la trazabilidad de los datos y la interoperabilidad con marcos regulatorios nacionales e internacionales como la Ley Argentina de Protección de Datos Personales (Ley 25326 de 2000) y el RGPD europeo (Reglamento UE 2016/679).

La investigación identificó como una de las principales limitaciones la escasa disponibilidad de bases de datos públicas de señales EMG. Por ello, una línea de desarrollo clave será la generación de *datasets* abiertos, anonimizados y validados clínicamente, que permitan el entrenamiento y evaluación de modelos DL y FL bajo estándares reproducibles. Como complemento metodológico a esta recolección de datos, se debe contemplar la recomendación aportada por el especialista en IA L. Valido (comunicación personal, 9 de junio de 2026): "Otro enfoque posible podría ser el *approach* 'Beyond the Lab', donde se guardan los datos de una prótesis experimental para poder ir iterando el producto".

La creación de un consorcio interinstitucional dedicado a recopilar y estandarizar señales EMG y EEG provenientes de distintos perfiles fisiológicos y patologías contribuiría a la democratización de la investigación biomédica, permitiendo el avance de la inteligencia artificial aplicada a la rehabilitación motora en contextos locales y globales.

Los hallazgos sobre la accesibilidad económica de las prótesis mioeléctricas sugieren la necesidad de investigaciones orientadas a evaluar modelos de producción y financiamiento sostenibles, que garanticen el acceso equitativo a la tecnología.

En este sentido, futuras líneas de trabajo deberían considerar la evaluación de costos, modelos de subsidios, fabricación local mediante impresión 3D y la implementación de programas públicos de inclusión tecnológica, buscando reducir la brecha entre el potencial científico y su adopción social. Esta línea interdisciplinaria podría integrar aportes de la ingeniería, la economía y las políticas públicas, consolidando un enfoque de innovación con impacto social real y medible.

Finalmente, se propone investigar sistemas de control multimodal que integren señales EMG con EEG, acelerometría o visión por computadora, permitiendo un control más natural, contextual y predictivo de la prótesis. El uso de técnicas de aprendizaje profundo multimodal y modelos atencionales podría mejorar la capacidad del sistema para anticipar la intención del usuario, reduciendo errores de movimiento y aumentando la sensación de naturalidad en la interacción hombre-máquina.

En conjunto, estas líneas de investigación configuran una agenda estratégica para el futuro de la inteligencia artificial biomédica aplicada a prótesis mioeléctricas. Esta planificación se articula, en primera instancia, a través de una profunda dimensión tecnológica basada en el perfeccionamiento continuo de modelos de *Deep Learning* (DL) y *Federated Learning* (FL), orientada a consolidar su viabilidad mediante rigurosas fases de validación experimental en entornos reales.

Por otra parte, esta evolución técnica se complementa con un fuerte compromiso ético, normativo y social. El objetivo es garantizar no solo la privacidad, equidad y transparencia de los sistemas inteligentes, sino también ampliar su impacto en la comunidad. De este modo, se busca asegurar la accesibilidad económica, la sostenibilidad de los dispositivos y una adopción efectiva y real dentro de los contextos clínicos y comunitarios.

En definitiva, los hallazgos de este trabajo abren un camino de investigación que trasciende lo técnico para situarse en el cruce entre innovación, ética y bienestar humano. El

futuro de las prótesis mioeléctricas inteligentes no solo dependerá de la potencia de los algoritmos, sino de la capacidad de las comunidades científicas y médicas de co-crear soluciones seguras, accesibles y personalizadas que devuelvan autonomía y calidad de vida a quienes más lo necesitan.

Anexos

Anexo I: Preguntas realizadas en el formulario de encuesta

URL del formulario: <https://forms.gle/HkWMCHnDD7CDkjbj6>

Preguntas para toda la población objetivo:

¿Cuál es tu área profesional o disciplina principal?

Años de experiencia en el campo

¿Considera ético el uso de datos como historial clínico y datos biométricos para entrenar modelos de IA personalizados, si se garantiza la privacidad?

¿Qué grado de riesgo ético percibís en el uso de estas tecnologías?

¿Qué medidas considera necesarias para proteger la privacidad de los usuarios en este contexto?

¿Considerás viable el uso del aprendizaje federado como alternativa para preservar la privacidad de los usuarios en este tipo de dispositivos?

¿Cuáles considera que son los mayores riesgos éticos asociados al uso de IA en dispositivos médicos personalizados como las prótesis mioeléctricas?

¿Qué mecanismos cree usted que deberían implementarse para proteger la privacidad de las personas usuarias de estas prótesis?

¿Cree que este tipo de prótesis sería accesible económicamente para la mayoría de los pacientes?

¿Qué factores podrían dificultar la adopción de estas prótesis?

¿Qué estrategias propondría para garantizar la equidad en el acceso a estas tecnologías?

En una escala del 1 al 5, ¿qué tan prometedor le parece el uso combinado de *Deep Learning* y Aprendizaje Federado para personalizar el control de prótesis mioeléctricas, cuidando la privacidad del usuario?

¿Le gustaría compartir algún comentario adicional, observación o recomendación sobre este enfoque?

Preguntas para los perfiles técnicos:

-
- ¿Creés que el uso de *Deep Learning* puede mejorar la personalización para imitar movimientos de brazos y piernas en prótesis?
- ¿Qué tan factible crees que es aplicar modelos de *Deep Learning* para personalizar el control de prótesis de brazos y piernas en pacientes reales?
- ¿Qué ventajas percibís en la aplicación de *Deep Learning* y Aprendizaje Federado en prótesis de brazos y piernas?
- ¿Qué condiciones serían necesarias para que esta tecnología se implemente en el sistema de salud?
- ¿Cuál considerás que es el principal desafío técnico para implementar IA personalizada en prótesis mioeléctricas?
- ¿Considerás viable técnicamente aplicar aprendizaje federado para entrenar modelos de IA personalizados sin vulnerar los datos de los usuarios?
- ¿Cuánto conocimiento técnico crees que requiere un profesional de salud para usar este tipo de tecnología?
- En su experiencia, ¿cuáles son los principales desafíos técnicos para implementar este tipo de tecnología en contextos reales?

Preguntas para los perfiles médicos:

- ¿Conocés o trabajás con Inteligencia Artificial?
- ¿Considera que el personal médico aceptaría fácilmente el uso de prótesis de brazos y piernas potenciadas con Inteligencia Artificial?
- ¿Estarías de acuerdo con que un sistema de Inteligencia Artificial acceda a los datos del paciente para personalizar una prótesis?
- ¿Qué tipos de datos creés que podrían considerarse sensibles al usar prótesis con Inteligencia Artificial?
- ¿Quiénes considerás que deberían participar del proceso de evaluación e implementación de esta tecnología? (Seleccioná todos los que correspondan)
- ¿Qué factor considerás más determinante para que esta tecnología sea aceptada clínicamente?
- ¿Cómo debería incorporarse esta tecnología en la práctica clínica?
- ¿Qué factores clínicos o de implementación podrían dificultar la adopción de este tipo de prótesis en instituciones de salud?

Anexo II: Entrevista realizada a especialista en IA y ciberseguridad

1. Mi encuesta señala que las limitaciones de *hardware* son el principal desafío técnico para integrar IA en prótesis. Desde su experiencia, ¿cuáles son los mayores cuellos de botella al intentar ejecutar modelos de IA directamente en dispositivos periféricos pequeños y de bajo consumo?

Respuesta: Los dispositivos pequeños generalmente no poseen gran capacidad de cálculo para poder ejecutar un modelo de IA integrado en un *device* de características IoT. Esto trae como derivado la necesidad de ejecutar el módulo de forma remota en un *backend* destinado a tal fin con la suficiente capacidad de cálculo. El problema de este último *approach* es que una prótesis debería poder ejecutarse siempre independientemente de la calidad de conexión existente en ese momento. Dicho de otra manera, el *device* no puede dejar de funcionar si no tengo conexión a internet. En estos casos se suele optar por modelos híbridos que permitan al dispositivo IoT tener autonomía prolongada mientras no haya conexión. Un ejemplo de esto último es la SUBE: Cualquier usuario puede usar la SUBE en cualquier lado, aunque el colectivo en cuestión esté fuera del área de alcance de internet. (La sube guarda el saldo disponible localmente). Tener en cuenta el consumo de batería.

2. Para que una prótesis se sienta natural, la respuesta al estímulo muscular debe ser casi inmediata. ¿Qué estrategias de arquitectura o *software* recomendaría para equilibrar una baja latencia (respuesta en tiempo real) con el peso computacional de un modelo de IA?

Respuesta: Ante este tipo de situaciones generalmente lo que se puede hacer es pre calcular los movimientos más comunes y factibles que una persona realiza y guardarla localmente en cada *device* (Muy similar a “Instrucciones para subir una escalera” de Cortázar). La contra de este modelo es que ante actualización hay que actualizar la memoria de todos los *devices*. La implementación termina siendo un mini árbol de decisión que permite limitar la cantidad de opciones. Por ejemplo, si ya tengo el brazo extendido, solo lo puedo mover a los costados o recogerlo).

3. Uno de los grandes problemas en mi campo es la falta de bases de datos estandarizadas y la alta variabilidad fisiológica entre cada paciente. En proyectos de IA en general, ¿cómo se aborda el entrenamiento de modelos robustos cuando los datos son escasos o muy heterogéneos?

Respuesta: Si bien es verdad que en este campo no vas a tener datos fidedignos, puedes generar algún tipo de emulador - simulador para hacer cualquier tipo de pruebas. Además, en base a material científico se puede entrenar el modelo para que haya *forecast* de valores futuros eventualmente. Otro enfoque posible podría ser el *approach* “*Beyond the Lab*”, donde se guardan los datos de una prótesis experimental para poder ir iterando el producto.

4. Mi trabajo final propone usar Aprendizaje Federado para que el modelo se entrene en la prótesis sin enviar datos crudos a la nube. Como profesional de IA, ¿qué ventajas operativas y qué riesgos o complicaciones técnicas le ve a este enfoque descentralizado frente al modelo tradicional en la nube?

Respuesta: Las ventajas son la privacidad y el aprendizaje *real time*. Las desventajas son la limitante de la capacidad de cómputo en el dispositivo, la complejidad en la sincronización de dispositivos (¿lo que aprendes en el *device* 1 cómo llevas ese aprendizaje al *device* 2?), la capacidad de cómputo ocioso la mayor parte del tiempo. Se debe sobre dimensionar la capacidad de cómputo del *device* solamente para la etapa de aprendizaje, posterior solo ejecuta lo aprendido (considerando que la persona no cambia la forma de moverse a lo largo del tiempo).

5. Al manejar señales biomédicas (datos sensibles), mi estudio muestra que la encriptación y el control de acceso son prioritarios. A nivel de infraestructura de *software*, ¿qué medidas de seguridad o cifrado considera indispensables hoy en día para asegurar que la transmisión de parámetros en un sistema de IA no sea vulnerada?

Las medidas de seguridad indispensables son: utilizar bases de datos en países autorizados, diferenciar datos SPII de datos PII y protección tipo cebolla de los datos a fin de evitar *leak* innecesarios.

Acrónimos

BCI: Interfaz Cerebro-Computadora
BNN: Redes Neuronales Bayesianas
BPTT: Retropropagación en el Tiempo
CNN: Redes Neuronales Convolucionales
DGM: Modelos Generativos Profundos
DL: Aprendizaje Profundo
DNN: Redes Neuronales Profundas
DP-SGD: Descenso de Gradiente Estocástico Diferencialmente Privado
EEG: Electroencefalográficas
EMG: Electromiográficas
EMR: Tasa de Coincidencia Exacta
FedAvg: Promedio Federado
FitDNN: Red Neuronal Profunda Plegada en el Tiempo
FL: Aprendizaje Federado
GAN: Redes Generativas Antagónicas
GCN: Redes Convolucionales de Gráficos
GPU: Unidades de Procesamiento Gráfico
GRU: Unidades Recurrentes Cerradas
IA: Inteligencia Artificial
IoMT: Internet de las Cosas Médicas
IoT: Internet de las Cosas
ISR: Rutina de Interrupción
KNN: K-Vecinos Más Cercanos
LDA: Análisis Discriminante Lineal
LLM: Grandes Modelos de Lenguaje
LSTM: Memoria a Corto y Largo Plazo
MAML: Meta Aprendizaje Agnóstico del Modelo
non-IID: No Independiente e Idénticamente Distribuido
PD: Privacidad Diferencial
Per-FedAvg: Federado Personalizado Promedio
PFL: Personalización Federada
PI: Intervalos de Predicción

PID: Proporcional-Integral-Derivativo
PII: Información de Identificación Personal
ResNet: Red Residual
RF: Bosques Aleatorios
RGPD: Reglamento General de Protección de Datos
RMS: Cálculo del Valor Eficaz
RNA: Redes Neuronales Artificiales
RNN: Redes Neuronales Recurrentes
SAE: Autoencoder Apilado
sEMG: Electromiografía de Superficie
SPII: Información Personal Identificable Sensible
SUBE: Sistema Único de Boleto Electrónico
SVM: Máquinas de Vectores de Soporte
TCN: Redes Convolucionales Temporales
TEA: Tasa de Error Activo
TFL: Aprendizaje Federado Tradicional
UQ: Cuantificación de la Incertidumbre
VAE: Auto Encodificadores Variacionales
VRE: Entornos Virtuales de Rehabilitación
XAI: Explicabilidad de la Inteligencia Artificial

Referencias

- Abdeltwab, A. A. (2025). Advances in Prosthetic Control: PID to Deep Learning. *Journal of Multidisciplinary Research for SMET (JMR-SMET)*, 1(1), 144-152. <https://doi.org/10.64297/jmrsmet.v1i1.16>
- Bustamante Gómez, S. (2015). *Prótesis robótica de miembro superior controlada por medio de interfaces neuronales: El estado del arte y un diseño conceptual* [Tesis de grado, Universidad Pontificia Bolivariana]. Repositorio Institucional UPB. <http://hdl.handle.net/20.500.11912/2499>
- Calero Valdez, A., & Ziefle, M. (2018). *The users' perspective on the privacy-utility trade-offs in health recommender systems*. arXiv. <https://arxiv.org/pdf/1804.04868>
- Chen, Z., Min, H., Wang, D., Xia, Z., Sun, F., & Fang, B. (2023). A Review of Myoelectric Control for Prosthetic Hand Manipulation. *Biomimetics*, 8, 328. <https://www.mdpi.com/2313-7673/8/3/328>
- Congreso de la Nación Argentina. (2000, 4 de octubre). *Ley 25326. Protección de los datos personales*. Boletín Oficial 29504. <https://servicios.infoleg.gob.ar/infolegInternet/verNorma.do?id=64790>
- Danezis, G., Domingo-Ferrer, J., Hansen, M., Hoepman, J.-H., Le Métayer, D., Tirtea, R., & Schiffner, S. (2014). *Privacy and data protection by design – From policy to engineering*. European Union Agency for Network and Information Security (ENISA). <https://arxiv.org/pdf/1501.03726>
- Dwork, C., & Roth, A. (2014). The algorithmic foundations of differential privacy. *Foundations and Trends® in Theoretical Computer Science*, 9(3–4), 211–407. <https://www.cis.upenn.edu/~aaroht/Papers/privacybook.pdf>
- Faust, O., Hagiwara, Y., Hong, T. J., Lih, O. S., & Acharya, U. R. (2018). Deep learning for healthcare applications based on physiological signals: A review. *Computers in*

-
- Biology and Medicine*, 100, 283–294. <https://pubmed.ncbi.nlm.nih.gov/29852952/>
- Gouda, M. A., Hong, W., Jiang, D., Feng, N., Zhou, B., & Li, Z. (2023). Synthesis of sEMG Signals for Hand Gestures Using a 1DDCGAN. *Bioengineering*, 10, 1353. <https://www.mdpi.com/2306-5354/10/12/1353>
- He, W., Jiang, Z., Xiao, T., Xu, Z., & Li, Y. (2026). A survey on uncertainty quantification methods for deep learning. *ACM Computing Surveys*, 58(7), Artículo 179. <https://doi.org/10.1145/3786319>
- Hernández-Sampieri, R., Fernández-Collado, C., & Baptista-Lucio, P. (2014). *Metodología de la investigación* (6.^a ed.). McGraw-Hill. <https://www.esup.edu.pe/wp-content/uploads/2020/12/2.%20Hernandez,%20Fernandez%20y%20Baptista-metodolog%C3%ADa%20Investigacion%20Cientifica%206ta%20ed.pdf>
- IBM. (s. f.). *¿Qué es el deep learning?* Consultado el 4 de julio de 2026. <https://www.ibm.com/es-es/think/topics/deep-learning>
- Kairouz, P., McMahan, H. B., Avent, B., Bellet, A., Bennis, M., Bhagoji, A. N., Bonawitz, K., Charles, Z., Cormode, G., Cummings, R., D'Oliveira, R. G. L., Eichner, H., El Rouayheb, S., Evans, D., Gardner, J., Garrett, Z., Gascon, A., Ghazi, B., Gibbons, P. B., ... Zhao, S. (2021). Advances and open problems in federated learning. *Foundations and Trends® in Machine Learning*, 14(1–2), 1–210. <https://arxiv.org/pdf/1912.04977>
- Kyranou, I., Vijayakumar, S., & Erden, M. S. (2018). Causes of performance degradation in non-invasive electromyographic pattern recognition in upper limb prostheses. *Frontiers Neurorobotics*, 12, 58. <https://doi.org/10.3389/fnbot.2018.00058>
- Lee, H., Jiang, M., & Zhao, Q. (2024). FedAssist: Federated learning in AI-powered prosthetics for sustainable and collaborative learning. *Proceedings of the 46th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*

(EMBC).

https://www-users.cse.umn.edu/~qzhao/publications/pdf/lee2024_fedassist.pdf

Mahecha Escarraga, J. A. (2015). *Las Prótesis Mioeléctricas* [Tesis de pregrado, Corporación Universitaria Minuto de Dios]. Repositorio UNIMINUTO.

<https://repository.uniminuto.edu/server/api/core/bitstreams/9f573da5-f9fa-499e-8fe3-86a46476be3f/content>

Malcolm, K., Uribe, C. A., & Yamagami, M. (2025). *Federated Learning in Open- and Closed-Loop EMG Decoding: A Privacy and Performance Perspective*. arXiv.

https://www.researchgate.net/publication/393784228_Federated_Learning_in_Open-and_Closed-Loop_EMG_Decoding_A_Privacy_and_Performance_Perspective

Mohammadi, M., Vejdanihemmat, M., Lotfinia, M., Rusu, M., Truhn, D., Maier, A., & Tayebi Arasteh, S. (2025). *Differential privacy for deep learning in medicine* [Preprint]. arXiv.

<https://doi.org/10.48550/arXiv.2506.00660>

Moreira, A., Pinto, M., Fernandes, M., Costa, J., Fidalgo, J., & Fantoni, A. (2026). Myoelectric controlled bionic robotic hand for voluntary finger motion driven by neuromuscular intent. *Machines*, 14(3), 355.

<https://www.mdpi.com/2075-1702/14/3/355>

Munné Argelich, B. (2022). *Building of a myoelectric prosthesis* [Tesis de pregrado, Universidad de Lleida]. Repositori Obert de la Universitat de Lleida.

<http://hdl.handle.net/10459.1/84394>

Organización Mundial de la Salud. (2017). *Normas de ortoprotésica de la OMS. Parte 1.*

Normas. <https://www.who.int/publications/i/item/9789241512480>

Ortosur. (2018). *Cómo funciona y se ajusta una prótesis mioeléctrica.*

<https://www.ortosur.es/como-funciona-protesis-mioelectrica/>

-
- Parlamento Europeo y Consejo de la Unión Europea. (2016, 27 de abril). *Reglamento (UE) 2016/679. Reglamento General de Protección de Datos (RGPD)*. Diario Oficial de la Unión Europea L 119/1. <https://eur-lex.europa.eu/eli/reg/2016/679/oj?locale=es>
- Rieke, N., Hancox, J., Li, W., Milletari, F., Roth, H. R., Albarqouni, S., Bakas, S., Galtier, M. N., Landman, B. A., Maier-Hein, K., Ourselin, S., Sheller, M., Summers, R. M., Trask, A., Xu, D., Baust, M., & Cardoso, M. J. (2020). The future of digital health with federated learning. *npj Digital Medicine*, 3, Article 119. <https://www.nature.com/articles/s41746-020-00323-1>
- Roche, A. D., Rehbaum, H., Farina, D., & Aszmann, O. C. (2014). Prosthetic Myoelectric Control Strategies: A Clinical Perspective. *Curr Surg Rep*, 2, 44. <https://doi.org/10.1007/s40137-013-0044-8>
- Stelzer, F., Röhm, A., Vicente, R., Fischer, I., & Yanchuk, S. (2021). Deep neural networks using a single neuron: folded-in-time architecture using feedback-modulated delay loops. *Nat Commun*, 12, 5164. <https://doi.org/10.1038/s41467-021-25427-4>
- Thapa, C., & Camtepe, S. (2020). *Precision health data: Requirements, challenges and existing techniques for data security and privacy*. arXiv. <https://arxiv.org/abs/2008.10733>
- UNESCO. (2022). *Recommendation on the ethics of artificial intelligence*. <https://www.unesco.org/en/articles/recommendation-ethics-artificial-intelligence>
- Wang, C., Feng, Z., Zhang, P., Cao, M., Yuan, Y., & Chang, T. (2025). *Robustness-enhanced Myoelectric Control with GAN-based Open-set Recognition*. arXiv. <https://arxiv.org/abs/2412.15819>
- Zaim, T., Abdel-Hadi, S., Mahmoud, R., Khandakar, A., Rakhtala, S. M., & Chowdhury, M. E. H. (2025). Machine Learning- and Deep Learning-Based Myoelectric Control System for Upper Limb Rehabilitation Utilizing EEG and EMG Signals: A

Systematic Review. *Bioengineering*, 12, 144.
<https://www.mdpi.com/2306-5354/12/2/144>

Zbinden, J., Molin, J., & Ortiz Catalan, M. (2024). Deep Learning for Enhanced Prosthetic Control: Real-Time Motor Intent Decoding for Simultaneous Control of Artificial Limbs. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 32, 1177-1186. <https://ieeexplore.ieee.org/document/10453986>