



UNIVERSIDAD AUTÓNOMA DE SAN LUIS POTOSÍ
FACULTAD DE CIENCIAS

DETECCIÓN DE LA INTENCIÓN DEL USUARIO EN TAREAS DE INTERACCIÓN HUMANO-ROBOT

TESIS PROFESIONAL

PARA OBTENER EL TÍTULO DE:

MAESTRO EN CIENCIAS DE LA VIDA

ORIENTACIÓN:

BIOINGENIERÍA

PRESENTA: IVÁN ALBERTO LUNA HERNÁNDEZ

DIRECTORES DE TESIS:

DR. MARCO OCTAVIO MENDOZA GUTIÉRREZ

DRA. ISELA BONILLA GUTIÉRREZ

SAN LUIS POTOSÍ, S.L.P. — JUNIO 2026

Licencia

Detección de la intención del usuario en tareas de interacción humano-robot © 2026
por Iván Alberto Luna Hernández tiene licencia [CC BY-NC-SA 4.0](https://creativecommons.org/licenses/by-nc-sa/4.0/).

Dedicatoria

*“A la memoria de mi abuelita;
su historia dio sentido a mi camino hacia la neuroingeniería.”*

Agradecimientos

A mis directores de tesis, gracias por la confianza y, sobre todo, por la libertad. Su apertura para que yo propusiera, tomara decisiones y participara activamente convirtió este trabajo en un proceso auténtico de formación, donde la guía no fue un límite, sino un impulso.

A SECIHTI, agradezco el apoyo económico brindado durante este periodo mediante la beca, la cual hizo posible dedicar tiempo y continuidad al desarrollo de esta investigación.

Al posgrado, gracias por su carácter multidisciplinario. Me obligó a pensar distinto, a escuchar otras formas de resolver y a reconocer que la ingeniería se fortalece cuando dialoga con otros lenguajes. Esa apertura amplió mi perspectiva y enriqueció el sentido de este proyecto.

A mis compañeros —y amigos— del posgrado: gracias por ser un sostén cuando las cosas se pusieron difíciles. En los días de cansancio, incertidumbre o presión, su compañía y conversación ayudaron a que el trabajo siguiera avanzando. También agradezco el privilegio de tener amistades dentro y fuera de mi área; esa mezcla de miradas y criterios ha sido una fuente diaria de aprendizaje, contraste y mejora.

A mi familia, gracias por su apoyo a su manera: quizá discreto, quizá a distancia, pero constante. No me han cuestionado de más, y aun así siempre he sabido que están ahí; que el día que lo necesite, la puerta seguirá abierta.

A Alejandra, gracias por ser mi soporte emocional y mi hogar en los días pesados. También por entender de cerca lo que implica el posgrado: por poder hablar contigo de ideas, dudas y avances con la misma claridad con la que se habla de la vida. Tu presencia sostuvo más de lo que alcanza a decir un párrafo.

Y, finalmente, me agradezco a mí. No como un gesto de cierre, sino como recordatorio: cuando todo se ve complicado, queda la posibilidad de intentarlo una vez más. He aprendido que la confianza no siempre llega primero; a veces se construye en el acto de seguir, incluso con miedo. Y que, si se falla, no se pierde del todo: la ganancia también está en haber tenido el coraje de probar.

Índice

Índice de tablas	11
Índice de figuras	15
Siglas, acrónimos y unidades	19
Resumen	21
Abstract	23
Capítulo 1 Introducción	25
1.1. Antecedentes	26
1.1.1. Detección de intención motora en interacción humano-robot	27
1.1.2. Fundamentos neurofisiológicos de la intención motora . . .	31
1.1.3. Señales fisiológicas y de movimiento para la detección de intención motora	32
1.1.4. Fusión multimodal EEG-sEMG: motivación y estrategias .	37
1.1.5. Implementación en tiempo real y aplicaciones en exoesque- letos de miembro superior	39
1.1.6. Síntesis de los antecedentes	43
1.2. Justificación	44
1.3. Hipótesis	48
1.4. Objetivo general	48
1.5. Objetivos particulares	49
1.6. Estructura de la tesis	49
Capítulo 2 Metodología	51
2.1. Diseño experimental y protocolo de adquisición de señales	53

2.2.	Procesamiento de señales y extracción de características	70
2.3.	Entrenamiento, validación y selección del modelo de clasificación	88
2.4.	Plataforma experimental	100
2.4.1.	Sistema robótico tipo exoesqueleto	104
2.4.2.	Arquitectura general del sistema HMI-exoesqueleto	108
2.4.3.	Máquina de estados y estrategias de seguridad	110
2.4.4.	Validación progresiva del sistema HMI-exoesqueleto	120
2.5.	Análisis estadístico	126
Capítulo 3 Resultados		128
3.1.	Optimización del modelo y selección de configuración	129
3.2.	Depuración de características y reducción de redundancias	132
3.3.	Validación progresiva del sistema en simulación	134
3.3.1.	Simulación <i>offline</i> con base de datos, sin exoesqueleto	134
3.3.2.	Simulación <i>online</i> con sujeto, sin exoesqueleto	139
3.3.3.	Simulación con exoesqueleto en lazo cerrado	143
3.4.	Resultados experimentales en tiempo real	145
3.5.	Análisis estadístico del desempeño experimental	151
Capítulo 4 Discusión		159
4.1.	Implicaciones del diseño del modelo de detección	160
4.1.1.	Balance entre resolución temporal y estabilidad de decisión	160
4.1.2.	Aporte de la reducción de redundancias y de la fusión multimodal	161
4.2.	Implicaciones de la validación progresiva del sistema	163
4.2.1.	Hallazgos de la simulación <i>offline</i>	164
4.2.2.	Retos observados en la simulación <i>online</i>	164
4.2.3.	Efecto de la integración del exoesqueleto en lazo cerrado	165

4.3. Interpretación del desempeño experimental en tiempo real	165
4.3.1. Robustez ante variación de condiciones	166
4.3.2. Generalización de sujetos desconocidos	167
4.3.3. Latencia útil, seguridad y estabilidad de control	167
4.3.4. Seguimiento de trayectoria y respuesta del exoesqueleto . .	169
4.3.5. Comparación con la literatura	170
4.4. Alcances estadísticos de los hallazgos	177
4.4.1. Tendencias descriptivas y variabilidad intersujeto	177
4.4.2. Efectos sistemáticos y ausencia de diferencias robustas . .	178
4.4.3. Relación entre precisión y latencia	179
Capítulo 5 Conclusiones	182
5.1. Conclusiones generales	183
5.2. Contribuciones técnicas	185
5.3. Limitaciones, casos límite y trabajo futuro	187
5.3.1. Limitaciones del estudio	187
5.3.2. Casos límite y fallos observables	189
5.3.3. Trabajo futuro	191
Referencias	201
Apéndices	202
A. Formato de consentimiento informado	203
B. Entornos e implementaciones computacionales	207
C. Configuración de parámetros para el controlador utilizado	208
D. Configuración de parámetros para las reglas de estados	210

E. Configuración del Banco CSP	211
F. Características crudas calculadas	212
G. Características después de limpieza de redundancias	214
H. Media e intervalo de confianza al 95 %	216
I. Resúmenes de modelos de ajuste para efecto aleatorio	219
J. Ajuste de relación precisión-latencia	221
K. Resultados experimentales para sujeto conocido	222
L. Resultados experimentales para sujeto desconocido	224

Índice de tablas

2.1. Bloques de movimiento y colocación de electrodos de sEMG del sistema Biosignalsplux.	60
2.2. Relación entre el protocolo de adquisición y las etapas posteriores de simulación y validación experimental.	69
2.3. Relación entre las características de EEG y su interpretación fisiológica o funcional dentro del protocolo experimental. Parte I. . . .	84
2.4. Relación entre las características de EEG y su interpretación fisiológica o funcional dentro del protocolo experimental. Parte II. . . .	85
2.5. Relación entre las características de sEMG y su interpretación fisiológica o funcional dentro del protocolo experimental.	86
2.6. Relación entre las características de IMU y su interpretación funcional dentro del protocolo experimental.	87
2.7. Relación entre búsqueda de hiperparámetros y esquemas de validación empleados durante el desarrollo del modelo.	95
2.8. Métricas y criterios utilizados en las distintas etapas de desarrollo y validación del sistema.	99
2.9. Distinción entre elementos heredados de la plataforma del laboratorio y aportaciones implementadas durante esta tesis.	101
3.1. Mejor configuración de segmentación identificada en la optimización inicial (L1).	130
3.2. Configuración seleccionada para el bloque CSP en L2 y desempeño obtenido durante su optimización.	130
3.3. Búsqueda gruesa de hiperparámetros SVM para los niveles L1 y L2.	131
3.4. Número de características por bloque antes y después de la limpieza de redundancias.	132

3.5. Resultados ponderados del primer bloque de simulaciones <i>offline</i> para los tres sujetos evaluados (denotados como S1, S2 y S16).	135
3.6. Matrices de confusión de las simulaciones para los sujetos 2, 1 y 16.	135
3.7. Precisión y sensibilidad ponderadas para las diferentes combinaciones de modalidades del sujeto 1.	136
3.8. Matriz de confusión para la simulación <i>offline</i> de la sesión del sujeto 1.	139
3.9. Reporte de clasificación para la simulación <i>offline</i> de la sesión del sujeto 1.	139
3.10. Matriz de confusión para la simulación <i>online</i> de la sesión del sujeto 2.	140
3.11. Reporte de clasificación para la simulación <i>online</i> de la sesión del sujeto 2.	140
3.12. Resumen de latencias de clasificación para decisiones estables para la Simulación 3.	145
3.13. Precisión media por sujeto y condición experimental, separando sujetos conocidos y desconocidos.	146
3.14. Sensibilidad media por sujeto y condición experimental, separando sujetos conocidos y desconocidos.	147
3.15. Latencia media (ms) por sujeto y condición experimental, separando sujetos conocidos y desconocidos.	147
3.16. Comparaciones <i>post-hoc</i> de precisión entre condiciones y grupos. .	156
3.17. Comparaciones <i>post-hoc</i> de sensibilidad entre condiciones y grupos.	156
3.18. Comparaciones <i>post-hoc</i> de latencia entre condiciones y grupos. .	157
3.19. Correlación entre precisión y latencia a nivel intra-sujeto.	157
4.1. Comparación del presente trabajo con estudios relacionados sobre detección de intención motora e interfaces robóticas de asistencia.	172
B.1. Entornos, bibliotecas e implementaciones computacionales utilizadas.	207

C.1. Valores generales de saturación y ganancia adaptativa utilizados en la configuración del controlador.	208
C.2. Parámetros del controlador de impedancia con acciones acotadas para el modelo de tres grados de libertad, agrupados por motor. .	209
D.1. Parámetros configurados en LabVIEW para las reglas de transición de la máquina de estados y la generación de referencias.	210
E.1. Banco CSP final utilizado en L2.	211
F.1. Resumen de características extraídas (crudas) para el clasificador L1.	212
F.2. Resumen de características extraídas (crudas) para el clasificador L2.	213
G.1. Características por modalidad para L1.	214
G.2. Características por modalidad para L2 (parte 1/2).	215
G.3. Características por modalidad para L2 (parte 2/2).	215
H.1. Media e intervalo de confianza al 95 % (IC95 %) de la precisión por condición y grupo de generalización.	216
H.2. Media e intervalo de confianza al 95 % (IC95 %) de la sensibilidad por condición y grupo de generalización.	217
H.3. Media e intervalo de confianza al 95 % (IC95 %) de la latencia (ms) por condición y grupo de generalización.	218
I.1. Modelo lineal mixto implementado mediante <i>MixedLM</i> para precisión con intercepto aleatorio por sujeto.	219
I.2. Modelo lineal mixto implementado mediante <i>MixedLM</i> para sensibilidad con intercepto aleatorio por sujeto.	219
I.3. Modelo lineal mixto implementado mediante <i>MixedLM</i> para latencia con intercepto aleatorio por sujeto.	220

J.1. Modelo lineal mixto implementado mediante <i>MixedLM</i> para precisión incluyendo latencia. Efecto aleatorio: intercepto por sujeto.	221
--	-----

Índice de figuras

2.1. Diagrama de flujo general del sistema HMI centrado en detección de intenciones.	52
2.2. Dispositivos y material utilizado durante la adquisición de señales.	59
2.3. Configuraciones de colocación de electrodos para la adquisición de señales de sEMG según el bloque experimental. (a) y (b) corresponden a los bloques de flexión/extensión de hombro y codo; (c) y (d) corresponden al bloque de rotación medial/lateral de hombro.	61
2.4. Estructura temporal del protocolo de adquisición de señales. Se resumen las fases de cada ensayo, el número de ensayos por bloque, los descansos entre bloques, la duración aproximada de la sesión y la repetición del protocolo en dos sesiones por participante.	66
2.5. Diagrama de bloques sobre la extracción de características.	71
2.6. Relación biomédica y funcional entre las fases del protocolo experimental, los eventos fisiológicos esperados y las señales EEG, sEMG e IMU utilizadas para la detección de intención motora.	74
2.7. Diagrama de bloques sobre la clasificación jerárquica, mostrando un ejemplo sobre la clasificación de la intención para una flexión.	89
2.8. Diagrama de flujo de las optimizaciones realizadas durante la extracción de características y el entrenamiento de los clasificadores.	92
2.9. Diagrama de bloques sobre la plataforma experimental y su conexión con el sistema HMI.	105
2.10. Plataforma experimental de tipo exoesqueleto utilizada.	106
2.11. Diagrama de flujo de una sesión típica de pruebas experimentales.	123
3.1. Comparación gráfica antes y después de la limpieza de redundancias para la etapa L1.	133

3.2. Comparación gráfica antes y después de la limpieza de redundancias para la etapa L2.	133
3.3. Resultados de simulación <i>offline</i> con sesión perteneciente al sujeto 1.	138
3.4. Resultados de simulación <i>online</i> con sesión perteneciente al sujeto 2.	141
3.5. Acercamiento de la simulación <i>online</i> donde se observan indecisiones del clasificador y conmutaciones breves en la referencia discreta.	142
3.6. Resultados de simulación <i>offline</i> con base de datos perteneciente al sujeto 2 y conexión de la HMI con el exoesqueleto.	144
3.7. Ejemplos de latencia en operación <i>online</i> . Se muestra el aumento de la latencia de clasificación entre dos sesiones diferentes.	150
3.8. Interacción de precisión entre grupo y condición. Las condiciones corresponden a: OC_pequeña, ojos cerrados con pesa pequeña; OC_grande, ojos cerrados con pesa grande; OA_grande, ojos abiertos con pesa grande; y OC_nada, ojos cerrados sin pesa. . .	152
3.9. Interacción de sensibilidad entre grupo y condición. Las condiciones corresponden a: OC_pequeña, ojos cerrados con pesa pequeña; OC_grande, ojos cerrados con pesa grande; OA_grande, ojos abiertos con pesa grande; y OC_nada, ojos cerrados sin pesa. . .	152
3.10. Interacción de latencia entre grupo y condición. Las condiciones corresponden a: OC_pequeña, ojos cerrados con pesa pequeña; OC_grande, ojos cerrados con pesa grande; OA_grande, ojos abiertos con pesa grande; y OC_nada, ojos cerrados sin pesa.	153

3.11. Distribución de la precisión por condición experimental y grupo de generalización. Las cajas representan la variabilidad entre sujetos para cada condición, mientras que los puntos individuales corresponden a los valores obtenidos por sujeto. Las condiciones corresponden a: OC_pequeña = ojos cerrados con pesa pequeña; OC_grande = ojos cerrados con pesa grande; OA_grande = ojos abiertos con pesa grande; OC_nada = ojos cerrados sin pesa. . .	153
3.12. Distribución de la sensibilidad por condición experimental y grupo de generalización. Las cajas representan la variabilidad entre sujetos para cada condición, mientras que los puntos individuales corresponden a los valores obtenidos por sujeto. Las condiciones corresponden a: OC_pequeña = ojos cerrados con pesa pequeña; OC_grande = ojos cerrados con pesa grande; OA_grande = ojos abiertos con pesa grande; OC_nada = ojos cerrados sin pesa. . .	154
3.13. Distribución de la latencia media por condición experimental y grupo de generalización. Las cajas representan la variabilidad entre sujetos para cada condición, mientras que los puntos individuales corresponden a los valores obtenidos por sujeto. Las condiciones corresponden a: OC_pequeña = ojos cerrados con pesa pequeña; OC_grande = ojos cerrados con pesa grande; OA_grande = ojos abiertos con pesa grande; OC_nada = ojos cerrados sin pesa. . .	154
3.14. Relación entre precisión y latencia media del sistema en la etapa experimental. Cada punto representa un bloque experimental correspondiente a un sujeto y una condición, diferenciando entre sujetos conocidos y desconocidos para el algoritmo. La figura permite explorar visualmente si existe un compromiso entre el desempeño de clasificación y el tiempo de respuesta del sistema.	158

K.1. Resultados experimentales en tiempo real para el sujeto 13 (conocido) en condiciones con ojos cerrados y carga externa.	222
K.2. Resultados experimentales en tiempo real para el sujeto 13 (conocido) en las condiciones de ojos abiertos con carga y ojos cerrados sin carga.	223
L.1. Resultados experimentales en tiempo real para el sujeto 20 (desconocido) en condiciones con ojos cerrados y carga externa.	224
L.2. Resultados experimentales en tiempo real para el sujeto 20 (desconocido) en las condiciones de ojos abiertos con carga y ojos cerrados sin carga.	225

Siglas, acrónimos y unidades

BCI	Brain-Computer Interface (Interfaz cerebro-computadora)
EEG	Electroencephalography (Electroencefalografía)
sEMG	Surface Electromyography (Electromiografía de superficie)
EMG	Electromyography (Electromiografía)
IMU	Inertial Measurement Unit (Unidad de medición inercial)
HRI	Human-Robot Interaction (Interacción humano-robot)
HMI	Human-Machine Interface (Interfaz humano-máquina)
ML	Machine Learning (Aprendizaje automático)
IA	Artificial Intelligence (Inteligencia artificial)
DL	Deep Learning (Aprendizaje profundo)
SVM	Support Vector Machine (Máquina de soporte vectorial)
KNN	K-Nearest Neighbors (K vecinos más cercanos)
CSP	Common Spatial Patterns (Patrones espaciales comunes)
DCA	Discriminant Correlation Analysis (Análisis de Correlación Discriminante)
ERD	Event-Related Desynchronization (Desincronización relacionada con eventos)
ERS	Event-Related Synchronization (Sincronización relacionada con eventos)
PSD	Power Spectral Density (Densidad espectral de potencia)
MI	Motor Imagery (Imaginación motora)
ICA	Independent Component Analysis (Análisis de Componentes Independientes)
DOF	Degrees of Freedom (Grados de libertad)

LOSuO Leave-One-Subject-Out (Validación dejando un sujeto fuera)

CSV Comma-Separated Values (Valores separados por comas)

UDP User Datagram Protocol (Protocolo de datagramas de usuario)

RBF Radial Basis Function (Función de base radial)

MNF Mean Frequency (Frecuencia Media)

MDF Median Frequency (Frecuencia Mediana)

RMS Root Mean Square (Raíz Cuadrada Media)

MAV Mean Absolute Value (Valor Absoluto Medio)

ZC Zero Crossing (Cruces por Cero)

NaN Not a Number (Valor no Numérico)

PLG Planetary GearBox (Caja de Engranajes Planetarios)

PC Personal Computer (Computadora personal)

cRIO CompactRIO

Hz hercio

ms milisegundo

s segundos

Resumen

En la robótica de asistencia, la detección de intención motora es un problema clave para lograr una interacción humano-robot segura, natural y adaptable, especialmente cuando las decisiones del sistema deben traducirse en acciones físicas en tiempo real.

En esta tesis se presenta el diseño, implementación y evaluación de un sistema multimodal de detección de intención motora orientado a apoyar el control seguro de un exoesqueleto de extremidad superior. El sistema integra adquisición y procesamiento de señales fisiológicas y de movimiento, clasificación jerárquica en dos niveles: L1 para reposo frente a movimiento y L2 para flexión frente a extensión, una máquina de estados con reglas de transición, generación de referencias de posición y control del exoesqueleto bajo criterios de seguridad, con el fin de operar en lazo cerrado en tiempo real.

La metodología contempló la adquisición de señales en 15 voluntarios sanos, fases progresivas de validación, simulaciones fuera de línea y en línea, así como experimentación en tiempo real y en lazo cerrado. En la etapa final se evaluó el desempeño con 10 participantes instrumentados: cinco pertenecientes al grupo inicial, cuyos datos habían formado parte del entrenamiento, y cinco participantes adicionales no incluidos previamente en el modelo. Por tanto, el estudio comprendió 20 participantes únicos. Esta distribución permitió comparar el desempeño entre sujetos conocidos y desconocidos para analizar la capacidad de generalización. El protocolo experimental consideró cuatro condiciones que combinaron variaciones de visión y carga externa.

En la experimentación final, las métricas globales se reportaron por sujeto y

condición (precisión, sensibilidad y latencia), permitiendo comparar el desempeño entre grupos (conocidos/desconocidos) y escenarios del protocolo. Asimismo, los promedios por condición mostraron precisiones medias en el rango 83–89 % tanto en sujetos conocidos como desconocidos, con latencias medias típicamente alrededor de 50–60 ms según la condición.

En conjunto, los resultados confirman la viabilidad de una estrategia multimodal para detección de intención y control asistivo en tiempo real, destacando la contribución de la fusión de señales y la evaluación sistemática de desempeño bajo condiciones controladas y con análisis de generalización a nuevos usuarios.

Abstract

In assistive robotics, motor-intention detection is a key problem for achieving safe, natural, and adaptive human–robot interaction, especially when system decisions must be translated into physical actions in real time.

In this thesis, the design, implementation, and evaluation of a multimodal motor-intention detection system are presented, aimed at supporting the safe control of an upper-limb exoskeleton. The system integrates the acquisition and processing of physiological and motion signals, a two-level hierarchical classification scheme in which L1 distinguishes rest from movement and L2 discriminates between flexion and extension, a state machine with transition rules, generation of position references, and exoskeleton control under safety criteria, enabling real-time closed-loop operation.

The methodology included signal acquisition from 15 healthy volunteers, progressive validation stages, *offline* and *online* simulations, as well as real-time and closed-loop experimentation. During the final stage, performance was evaluated with 10 instrumented participants: five from the initial group, whose data had been included in model training, and five additional participants who had not previously been included in the model. Therefore, the study involved 20 unique participants. This distribution enabled a comparison between subjects known and unknown to the algorithm in order to assess its generalization capability. The experimental protocol considered four conditions involving variations in vision and external load.

In the final experimentation, global metrics were reported per subject and condition (precision, recall, and latency), allowing performance comparisons between

groups (known vs. unseen) and across protocol scenarios. Condition-wise averages showed mean precision values within the range 83–89% for both known and unseen subjects, with mean latencies typically around 50–60 ms depending on the condition.

Overall, the results confirm the feasibility of a multimodal strategy for real-time intent detection and assistive control, highlighting the contribution of signal fusion and a systematic performance evaluation under controlled conditions, including an analysis of generalization to new users.

01

Introducción

Contexto y motivación del sistema

En este primer Capítulo se presenta el contexto del problema y se delimita el alcance del sistema propuesto para la detección de intenciones en un entorno de asistencia robótica. Posteriormente, se revisan los antecedentes y el marco teórico necesario para fundamentar la adquisición multimodal, el procesamiento de señales y la clasificación en tiempo real, con el fin de justificar las decisiones metodológicas adoptadas en los Capítulos siguientes.

1.1. Antecedentes

La robótica de asistencia y rehabilitación ha evolucionado hacia sistemas que no solo ejecutan trayectorias predefinidas, sino que buscan interpretar la intención del usuario y ajustar el nivel de asistencia de manera adaptativa. Esta transición responde a un objetivo central: aumentar la naturalidad, seguridad y efectividad de la interacción humano-robot mediante estrategias donde el robot se acopla al usuario y modula su respuesta en función del estado neuromuscular y del contexto de la tarea [1, 2, 3]. En este sentido, la detección de intención motora se considera una pieza clave, ya que habilita la conversión desde señales humanas, como lo son las señales bioeléctricas y cinemáticas, hacia comandos de control interpretables por el sistema robótico, reduciendo la dependencia de controles manuales o interfaces no intuitivas [4, 5].

A pesar de los avances, la intención motora es una variable latente y su estimación enfrenta distintos retos clásicos; específicamente la variabilidad inter- e intra-sujeto, la posible degradación por fatiga, cambios de colocación de sensores, presencia de artefactos, y la necesidad de operar con baja latencia. Por ello, la literatura reciente converge en dos líneas complementarias; primero el desarrollo de métodos robustos de reconocimiento de intenciones con sensores fisiológicos, neuronales y mecánicos; y segundo, su integración con esquemas de control de interacción, sean por admitancia, impedancia o compliancia, orientados a la segu-

ridad y estabilidad en lazo cerrado [6, 7].

En este contexto, el presente trabajo se alinea con una tendencia clara: la construcción de un sistema multimodal, con un flujo completo de adquisición, procesamiento, fusión y clasificación, orientado a una implementación en tiempo real e integración en una plataforma experimental. Esta visión coincide con trabajos que han demostrado que la combinación de modalidades y una arquitectura de decisión adecuada pueden mejorar confiabilidad, reducir falsas activaciones y favorecer el desempeño en escenarios realistas [8, 9, 10].

1.1.1. Detección de intención motora en interacción humano–robot

En robótica de rehabilitación, la intención suele definirse como la clase o fase de movimiento deseada por el usuario; por ejemplo, iniciar, mantener o terminar un gesto; y en enfoques más avanzados, como un conjunto de estados que incluyen esfuerzo, atención, o el grado de participación activa. Esta estimación se realiza a partir de mediciones fisiológicas y/o neuromecánicas, es decir, un conjunto de registros y mediciones con los cuales se obtiene información traducible a comandos que guían la asistencia robótica [1, 2].

Desde el punto de vista metodológico, los antecedentes pueden agruparse en tres bloques principales:

1. El reconocimiento de intenciones basado en sensores periféricos, principalmente con el uso de señales de electromiografía (EMG, por sus siglas en inglés, *electromyography*), a veces combinadas con ángulos o señales de movimiento. Es ampliamente estudiado por su relación directa con la activación muscular y por su utilidad práctica para el control de exoesqueletos [11, 12, 13].
2. El enfoque basado en señales de electroencefalografía (EEG, por sus siglas en inglés, *electroencephalography*), el cual permite capturar información cortical

asociada con la planificación y la preparación motora, lo que es útil incluso cuando la activación muscular es limitada. Así es como su uso en neurorehabilitación se documenta en diversos sistemas y paradigmas de las interfaces cerebro-computadora (BCIs, por sus siglas en inglés, *brain-computer interfaces*) [14, 15, 16].

3. Como un tercer bloque, los enfoques multimodales, con el uso de información proveniente de señales de EEG, EMG y otras variantes. Este enfoque se basa en buscar la complementariedad de las señales, una mayor robustez y la reducción de ambigüedad, lo que es particularmente valioso en condiciones de ruido y variabilidad humana [8, 9, 10, 17].

Sin embargo, la literatura coincide en que el principal obstáculo para pasar de prototipos a sistemas operativos en lazo cerrado es la confiabilidad temporal, ya que no basta con clasificar bien las intenciones; el sistema debe evitar fluctuaciones, controlar falsas activaciones y mantener una latencia compatible con la interacción humana [18, 19]. Por esto, se vuelve natural que muchos trabajos integren el reconocimiento de intenciones dentro de un marco de control que tolere incertidumbre y mantenga la seguridad del usuario, como se observa en revisiones y propuestas de control adaptativo y estrategias de compliancia para exoesqueletos [1, 3, 7].

Estos retos motivan a revisar con mayor profundidad las distintas modalidades de señales posibles a registrar y su fundamento, ya que de esto depende el diseño del protocolo de adquisición y el flujo del procesamiento completo.

Algoritmos para procesamiento y detección de intenciones motoras

El reconocimiento de intención típicamente sigue una cadena de etapas: pre-procesado, extracción de características, selección/reducción y clasificación. La literatura destaca que el rendimiento en condiciones reales depende tanto de la

calidad del modelo como de la estabilidad del flujo de procesado que sigue la señal [2, 6].

Para la EEG, una estrategia ampliamente reportada es la exploración de información espacial y espectral. En particular, enfoques basados en patrones espaciales comunes (CSP, por sus siglas en inglés, *common spatial patterns*) y variantes sobre bancos de sub-bandas se han utilizado para capturar patrones discriminativos en la actividad sensoriomotora, y pueden integrarse con representaciones tiempo-frecuencia cuando se busca robustez ante variaciones de contenido espectral [20]. En contextos de BCIs y neurorehabilitación, también se reportan combinaciones de rasgos de EEG que buscan mejorar la generalización, así como reducir tiempos de calibración [14, 15].

En EMG, el uso de rasgos temporales y espectrales continúa siendo común por su bajo costo computacional y compatibilidad con tiempo real. No obstante, diversos trabajos enfatizan que el problema de intención no consiste en reconocer algún gesto, sino en hacerlo con estabilidad en transiciones y bajo variación de ejecución. Por esto, es común ver una integración con señales angulares, así como con arquitecturas de decisión que manejan fases de inicio, mantenimiento y fin de la intención [11, 21].

Un punto fundamental es la mitigación de artefactos y la robustez del sistema ante fuentes de ruido. En EEG, se han propuesto métodos de remoción de artefactos oculares en tiempo real, lo que ilustra el interés por procesos de limpieza compatibles con latencias bajas [22]. En EMG y sensores mecánicos, la robustez se aborda con normalizaciones, estrategias de segmentación temporal y, cuando es posible, redundancia multimodal [6, 21].

Con el propósito de tener un análisis multimodal robusto, inter-sujeto y en tiempo real, los antecedentes convergen en el uso de la inteligencia artificial (IA), donde, una vez definidas las representaciones y características, los modelos deben

aprender a generalizar y producir decisiones confiables.

Uso de inteligencia artificial en la detección de intenciones motoras

La IA ha permitido formalizar el reconocimiento de intenciones como un problema de clasificación con modelos capaces de capturar relaciones no lineales y variabilidad humana. En rehabilitación robótica, se observan desde modelos clásicos, como máquinas de soporte vectorial (SVMs, por sus siglas en inglés, *support vector machines*), K vecinos más cercanos (KNN, por sus siglas en inglés, *k-nearest neighbors*) y algoritmos de aprendizaje automático (ML, por sus siglas en inglés, *machine learning*) y aprendizaje profundo (DL, por sus siglas en inglés, *deep learning*) aplicado sobre señales crudas o representaciones transformadas, con el objetivo de mejorar la robustez y reducir la ingeniería manual de características [2].

En el desarrollo de BCIs y neurorehabilitación existen antecedentes que integran señales de EEG en diseños de interacción humano-robot (HRI, por sus siglas en inglés, *human-robot interaction*), a veces combinando múltiples fuentes y rasgos. Este tipo de trabajos refuerza el valor de aproximaciones basadas en aprendizaje supervisado y estrategias cuidadosas de extracción de características [14, 15]. Por otra parte, en tareas de intención asociadas a movimiento y exoesqueletos, la IA frecuentemente se inserta dentro de un esquema más amplio que incluye control de interacción y seguridad. Aquí, el modelo debe ser no solo preciso, sino también confiable en el tiempo y compatible con ejecución en *hardware* de tiempo real [1, 19].

Una tendencia práctica es emplear arquitecturas jerárquicas o por etapas para reducir falsas activaciones. Aunque la literatura lo implementa con distintas variantes, desde una fusión de decisiones, entrenamiento por confianza, o una clasificación multi-etapa, el objetivo es el mismo: estabilizar el flujo de control y

evitar que el robot responda a predicciones no definidas correctamente [18, 19].

Esta consideración conduce directamente al problema de implementación en tiempo real. En este contexto, la evaluación fuera de línea (*offline*) se refiere al análisis de señales previamente adquiridas, mientras que la evaluación en línea (*online*) implica procesar las señales conforme se reciben y generar decisiones bajo restricciones temporales. Por esto, la IA no solo debe ser útil en términos de clasificación, sino también operar dentro de límites de latencia y estabilidad. Es por esto que la siguiente subsección enfatiza la implementación *online* y el manejo temporal del sistema.

1.1.2. Fundamentos neurofisiológicos de la intención motora

La intención motora puede entenderse como un proceso previo y concurrente a la ejecución voluntaria del movimiento, en el que participan mecanismos de planificación, preparación y control motor. Desde una perspectiva neurofisiológica, estos procesos involucran regiones corticales asociadas al sistema sensoriomotor, incluyendo áreas motoras y somatosensoriales que participan en la generación, modulación y retroalimentación del movimiento. Por ello, antes de que la acción sea observable de manera mecánica, pueden presentarse cambios en la actividad cortical relacionados con la preparación o imaginación del movimiento.

En registros de EEG, la actividad motora se ha asociado principalmente con cambios oscilatorios sobre regiones centrales del cuero cabelludo, correspondientes de manera aproximada a la corteza sensoriomotora. En el sistema internacional 10–20, estas regiones suelen explorarse mediante electrodos centrales, como C3, Cz y C4, o posiciones cercanas. En este trabajo, el registro se concentró en canales centrales equivalentes a C1–C6, con el propósito de cubrir la región sensoriomotora relacionada con movimientos del miembro superior.

Dos bandas de interés en este contexto son la banda mu, aproximadamente

entre 8 y 13 Hz, y la banda beta, aproximadamente entre 13 y 30 Hz. La banda mu (μ) se ha relacionado con ritmos sensoriomotores que tienden a disminuir su potencia durante la ejecución o imaginación de movimientos, fenómeno denominado desincronización relacionada con eventos (ERD, por sus siglas en inglés, *event-related desynchronization*). De manera complementaria, el aumento relativo de potencia respecto a una condición basal se denomina sincronización relacionada con eventos (ERS, por sus siglas en inglés, *event-related synchronization*). La banda beta (β) también forma parte de la dinámica sensoriomotora y se ha asociado con procesos de preparación, mantenimiento del estado motor y reorganización posterior al movimiento. Por esta razón, el análisis de estas bandas permite obtener información útil sobre estados de reposo, preparación, ejecución e imaginación motora (MI, por sus siglas en inglés, *motor imagery*) [14, 22, 20].

A partir de este fundamento, la detección de intención motora se plantea como la inferencia de un estado funcional a partir de señales asociadas con distintas etapas del proceso motor. En las siguientes subsecciones se describen las modalidades empleadas para este propósito, así como la motivación para combinarlas en una estrategia multimodal.

1.1.3. Señales fisiológicas y de movimiento para la detección de intención motora

La señal de EEG registra la actividad eléctrica cortical y ha sido ampliamente utilizada en interfaces cerebro-computadora para inferir estados relacionados con la intención y la preparación de movimiento. En el contexto de esta tesis, su relevancia radica en que permite observar cambios asociados con la etapa cortical del proceso motor, particularmente sobre regiones sensoriomotoras relacionadas con la planificación, ejecución e imaginación de movimientos del miembro superior. Como se mencionó previamente, en estas tareas resultan de especial interés

los cambios espectrales en las bandas mu y beta, por lo que es común aplicar representaciones en frecuencia o tiempo–frecuencia, así como métodos que exploren características espaciales [14, 20]. En aplicaciones clínicas, también se han reportado marcadores de EEG asociados a afectación de extremidad superior en pacientes con evento vascular cerebral, lo cual refuerza la relevancia de la señal de EEG como fuente de información para rehabilitación y evaluación funcional [16].

No obstante, la señal de EEG es altamente sensible a distintos artefactos como pueden ser oculares, musculares, ambientales y a variaciones experimentales. Por ello, distintos trabajos destacan la necesidad de mecanismos de limpieza y/o remoción de artefactos con viabilidad computacional, especialmente cuando el objetivo es el funcionamiento en tiempo real [22]. Este punto es crucial porque obliga a equilibrar la pureza de la señal con la relación de costo de procesamiento y latencia.

Por otra parte, la electromiografía de superficie (sEMG, por sus siglas en inglés, *surface electromyography*) captura actividad muscular periférica asociada con la activación de unidades motoras durante la contracción. Desde el punto de vista fisiológico, esta señal representa una etapa posterior al componente cortical observado con EEG, ya que refleja la traducción neuromuscular de la intención hacia una activación muscular observable. Por esta razón, la sEMG se ha consolidado como una señal de referencia para inferir intención motora en exoesqueletos, especialmente cuando existe activación residual [11, 12]. En estudios de reconocimiento de movimiento, la EMG suele combinarse con rasgos temporales y espectrales, utilizando clasificadores que buscan robustez a variaciones en la contracción muscular [11]. A nivel de sistemas, existen antecedentes de control de exoesqueletos basados en intención obtenida desde sEMG, tanto en propuestas de asistencia articular como en marcos de interacción usuario-exoesqueleto con retroalimentación y estrategias de control centradas en el usuario [4, 5, 13].

A pesar de su utilidad, la señal de EMG también presenta desafíos: como la variabilidad por fatiga, por cambios en los electrodos y diferencias interpersonales. Precisamente por esto, muchos trabajos proponen complementar la EMG con sensores cinemáticos para robustecer la decisión en fases donde la EMG puede ser débil o confusa [8, 21].

De manera adicional, las señales provenientes de una unidad de medición inercial (IMU, por sus siglas en inglés, *inertial measurement unit*) permiten medir la aceleración y velocidad angular usando acelerómetros, giroscopios y magnetómetros. Aunque estas señales no registran directamente actividad fisiológica, aportan información sobre la manifestación cinemática del proceso motor, es decir, sobre cómo la intención y la activación muscular se expresan finalmente como movimiento del segmento corporal. Por ello, ofrecen una ventana directa a la cinemática y actúan como soporte para identificar transiciones entre reposo, ejecución y mantenimiento del gesto [6, 21]. En el caso de exoesqueletos, también son útiles para identificar eventos de cambio de estado y para cerrar el lazo de control con estimación del estado mecánico [6]. En literatura de fusión multimodal, se ha demostrado que integrar señales neuromecánicas puede mejorar la confiabilidad de reconocimiento, sobre todo en escenarios dinámicos donde una sola modalidad puede fallar temporalmente [21].

La relevancia relativa de cada modalidad también depende del tipo de aplicación. En rehabilitación neuromotora, el EEG permite observar procesos corticales relacionados con atención, preparación e imaginación motora, por lo que puede aportar evidencia de participación activa incluso cuando la activación muscular es limitada; la sEMG permite cuantificar la activación residual y el esfuerzo muscular, mientras que la IMU facilita evaluar la ejecución, amplitud y estabilidad del movimiento [6, 16]. En prótesis activas, la sEMG suele constituir la principal señal de mando, debido a su relación directa con la activación de los músculos

residuales y su capacidad para discriminar gestos o estimar comandos, mientras que la IMU puede complementar la decisión mediante información sobre postura y contexto cinemático; el EEG puede ser útil cuando la señal muscular disponible es insuficiente, aunque su instrumentación y sensibilidad a artefactos dificultan su uso cotidiano [23]. En exoesqueletos, las tres modalidades presentan una complementariedad particular: el EEG aporta información previa o concurrente a la acción, la sEMG refleja la respuesta neuromuscular y la IMU confirma su expresión mecánica. Esta combinación resulta especialmente relevante cuando la intención estimada debe traducirse en asistencia física segura y estable [4, 5, 6].

Protocolo de adquisición multimodal de señales

En la literatura, los protocolos multimodales para la detección de intención varían ampliamente en número de sujetos, estructura temporal y volumen de repeticiones, lo cual impacta directamente en la generalización inter-sujeto, la estabilidad temporal y la viabilidad en tiempo real. Por esto, es útil describir explícitamente los elementos cuantitativos principales, ya que constituyen la base metodológica sobre la cual se interpreta el desempeño de los modelos.

En paradigmas clásicos de BCIs basadas en MI, se han reportado protocolos con múltiples clases y alta densidad de ensayos por clase. Por ejemplo, Blankertz et al. emplearon 10 voluntarios sanos (con poca o nula experiencia previa) y reportaron 140 ensayos por clase de MI, analizando movimientos de mano izquierda, mano derecha y pie, lo cual permite entrenar y evaluar modelos bajo una cantidad considerable de repeticiones por categoría, aunque manteniendo el reto de la variabilidad inter-sujeto típica de la señal de EEG [14].

En un enfoque orientado a un exoesqueleto y tareas funcionales, Li et al. reportaron un protocolo con 14 voluntarios sanos, diseñado específicamente para tareas de marcha asistida con un exoesqueleto [8]; sin embargo, el artículo no

especifica de forma explícita el número exacto de repeticiones, lo cual ilustra una limitación frecuente en reportes experimentales: la ausencia de detalles completos de adquisición dificulta la replicabilidad directa del protocolo y la comparación cuantitativa entre estudios.

En contextos donde se busca demostrar viabilidad en una población clínica, suele observarse un tamaño muestral reducido, acompañado de múltiples sesiones para controlar la variabilidad día a día. Broniera et al. realizaron un estudio piloto con un voluntario con paraplejía, llevando a cabo dos pruebas experimentales principales en días distintos, además de una fase de calibración previa basada en imaginación motora sobre movimientos de pierna derecha y reposo. Este diseño prioriza la demostración de factibilidad y estabilidad inter-sesión por encima del análisis estadístico poblacional amplio, y subraya el reto de operar con señales de alta variabilidad y potencialmente menor relación señal-ruido [24].

Por otro lado, cuando el objetivo es la detección asíncrona o continua en tareas dinámicas, como lo es la marcha auto-iniciada, se han descrito protocolos con segmentación por sesiones y alta cantidad de ciclos funcionales por sujeto. Hasan et al. reportaron 6 voluntarios sanos y aproximadamente 140 ciclos de marcha auto-iniciados por sujeto, distribuidos en 6-7 sesiones por participante, lo cual sugiere una estrategia de adquisición orientada a capturar variabilidad temporal, como la fatiga, el aprendizaje o los cambios de ejecución, y a evaluar modelos bajo condiciones más cercanas a la operación real [18].

En conjunto, estos antecedentes señalan retos recurrentes para la adquisición multimodal, como la presencia de artefactos y ruido, en especial en señales de EEG; también la variabilidad inter-sujeto e inter-sesión; y tercero, la necesidad de una segmentación y etiquetado temporal consistentes para entrenar modelos que funcionen en tiempo real [6, 22].

1.1.4. Fusión multimodal EEG-sEMG: motivación y estrategias

La motivación de la fusión multimodal parte del principio de que, en condiciones reales de operación, las modalidades basadas exclusivamente en EEG o sEMG pueden presentar degradaciones intermitentes debidas a diversos aspectos como ruido, cambios de postura, fatiga o interferencias. Por ello, al combinar señales EEG y sEMG, asociadas respectivamente con procesos corticales y con la ejecución muscular, se busca obtener una evidencia de intención más estable a lo largo del tiempo y más robusta entre sujetos [8, 10, 17]. Esta idea se refleja de forma clara en diseños de interfaces humano-máquina (HMIs, por sus siglas en inglés, *human-machine interfaces*) y control de exoesqueletos donde la intención no depende de una sola señal, sino de la integración de múltiples fuentes de información [9, 10].

Las estrategias de fusión suelen clasificarse en:

1. **Fusión a nivel de características.** En la cual, se extraen rasgos de EEG y de EMG, se concatenan en un vector conjunto y se entrena un clasificador sobre ese espacio multimodal. Este enfoque es viable cuando se dispone de un esquema de extracción bien definido y que permite aplicar una selección de características o reducción dimensional para manejar redundancias [20, 17, 10].
2. **Fusión a nivel de decisión.** En este enfoque, se entrenan clasificadores separados por modalidad y se combinan sus salidas, ya sea por voto, ponderación por confianza, o por reglas jerárquicas. Este enfoque suele ser conveniente cuando las modalidades difieren en tasa de muestreo, latencia efectiva o confiabilidad contextual, y permite introducir diversas lógicas de seguridad [10, 19].
3. **Fusión orientada al control.** Aquí la salida fusionada no solo decide la

clase, sino que modula parámetros de interacción, por ejemplo, por rigidez, amortiguamiento y/o ganancia de asistencia. Esto es especialmente visible en propuestas donde la fusión de EEG-EMG alimenta esquemas de control adaptativo para exoesqueletos, integrando intención y compliancia [9, 1].

En conjunto, estos trabajos sustentan que la fusión multimodal puede aportar tanto a la detección de intención como a la integración con controladores, siempre que se cuide el compromiso entre exactitud y latencia de procesamiento; por eso, es relevante analizar hasta qué punto se ha explotado la mejora de la precisión sin descuidar la latencia.

Fusión multimodal EEG-sEMG: evidencia experimental

En primer lugar, se han propuesto esquemas en cascada que aprovechan el carácter complementario de ambas modalidades. En un enfoque de predicción por etapas evaluado en 12 sujetos y cinco tareas, se reportó una precisión máxima de predicción de 96.58 % con un tiempo de cómputo aproximado de 51.89 ms, destacando la viabilidad del enfoque para sistemas con restricciones temporales [2]. Esto sugiere que, además de la fusión como tal, la arquitectura de decisión influye en el balance entre desempeño y costo computacional.

En segundo lugar, existen estrategias de fusión a nivel de características que buscan maximizar la información compartida entre EEG y sEMG. Un ejemplo es el uso del análisis de correlación discriminante (DCA, por sus siglas en inglés, *discriminant correlation analysis*) para fusionar EEG-EMG en reconocimiento de movimientos de miembro inferior, donde se alcanzó una exactitud máxima de $96.64 \pm 4.48\%$ con una ventana de 250 ms. En ese mismo trabajo se reporta un tiempo total de ejecución de 255.756 ms (extracción en 3.063 ms + predicción en 2.690 ms + duración de ventana), manteniéndose dentro de umbrales comúnmente deseables para aplicaciones en tiempo real [10].

Complementariamente, otros estudios han mostrado que incluso fusiones más directas pueden mejorar el desempeño respecto a usar una sola modalidad. En clasificación de movimientos unilaterales del pie, se reportó que la señal fusionada EEG–EMG alcanzó una exactitud de 98.07 % para una tarea de dorsiflexión mientras que el peor caso fue 78.97 % en flexión plantar, evidenciando que el beneficio puede variar por clase y que el desempeño está condicionado por la naturaleza del movimiento [17].

Finalmente, también se ha explorado la fusión EEG–EMG no solo para clasificación, sino como parte de estrategias de control en exoesqueletos. En un exoesqueleto de mano con actuadores elásticos en serie, se propone un control por admitancia basado en fusión EEG–EMG, donde el EEG se utiliza para estimar el nivel de concentración y el EMG para la intención de movimiento, buscando ajustar la dificultad/seguimiento durante la rehabilitación [9].

En general, la fusión multimodal aporta redundancia, pero también introduce nuevos retos, como tener una correcta sincronización, el escalamiento de rasgos, manejo de ventanas, y diseño de una arquitectura de decisión que no sea frágil ante ruido. Por esto, el siguiente paso es explorar cómo se procesan estas señales y qué algoritmos suelen emplearse para extraer información discriminativa.

1.1.5. Implementación en tiempo real y aplicaciones en exoesqueletos de miembro superior

En el estado del arte es común distinguir entre evaluación *offline*, evaluación *online* y operación en tiempo real, ya que representan niveles crecientes de realismo y diversas restricciones. La evaluación *offline* se realiza con señales previamente adquiridas y segmentadas, donde el modelo se entrena y prueba sin restricciones estrictas de latencia; aunque permite comparar algoritmos y ajustar hiperparámetros, puede sobreestimar el desempeño si la segmentación o el preprocesado

usan información “ideal” no disponible durante la operación real. La evaluación *online* reproduce el flujo secuencial de la adquisición mediante ventanas deslizantes y decisiones consecutivas, incorporando efectos temporales como acumulación de falsas detecciones, estabilidad entre ventanas y retardo efectivo por ventaneo; sin embargo, todavía puede ejecutarse sobre datos grabados. Finalmente, la operación en tiempo real implica que la señal entra al sistema conforme se adquiere y el modelo emite decisiones con restricciones estrictas de cómputo, sincronización y comunicación, además de que dichas decisiones pueden generar acciones físicas, por lo que la seguridad y la confiabilidad temporal se vuelven requisitos tan importantes como la precisión [18, 19, 6].

La operación en tiempo real impone restricciones que muchas veces no se reflejan en evaluaciones *offline*: la decisión debe emitirse con latencia suficientemente baja, de forma consistente, y con un nivel de incertidumbre manejable para no comprometer la seguridad del usuario. En sistemas asíncronos de BCIs, se ha estudiado explícitamente la detección de estados de forma continua, mostrando la importancia del manejo temporal para reducir falsas detecciones cuando el usuario no está actuando [18]. Asimismo, en demostraciones de BCIs se discuten estrategias de calibración y operación práctica que subrayan que el desempeño no depende solo del algoritmo, sino del diseño experimental y del funcionamiento *online* [14].

En robótica de asistencia, la funcionalidad en tiempo real no solo es una cuestión computacional; también es un requisito perceptual y de seguridad, ya que un retardo excesivo puede hacer que la asistencia sea incómoda, mientras que fluctuaciones rápidas pueden generar inestabilidad o movimientos no deseados. En este contexto, se reportan aproximaciones de predicción del orden de decenas de milisegundos, específicamente de 50 milisegundos (ms), para variables articulares, lo cual sugiere escalas temporales compatibles con control asistivo si el procesa-

miento se mantiene eficiente [1]. Por ello, se suelen introducir reglas de decisión temporal sobre el suavizado, ventanas deslizantes y estados finitos, y se planean mecanismos de verificación, por ejemplo, confirmación por múltiples ventanas o por modalidades redundantes [19, 6]. En este caso, es un componente relevante, ya que el objetivo final es cerrar el ciclo con un exoesqueleto y un sistema de control donde las predicciones se traducen a una acción física.

A partir de este punto, la intención clasificada se integró en un sistema de mayor alcance: el exoesqueleto y su controlador.

Implementación en exoesqueletos y sistemas de control

Los exoesqueletos para rehabilitación y asistencia requieren controladores capaces de interactuar de forma segura con el usuario. Dentro de los enfoques más citados se encuentran estrategias de impedancia/admitancia, control de compliancia, y control adaptativo basado en intención. Revisiones recientes enfatizan que el reconocimiento de intención debe acoplarse con un control de interacción para lograr una asistencia efectiva, especialmente en escenarios clínicos como la rehabilitación [3, 1].

En particular, el control de impedancia con acciones acotadas es un antecedente relevante porque formaliza restricciones que son críticas en la HRI, como la limitación de fuerzas/torques, la estabilidad ante incertidumbre y una mayor seguridad [7]. A nivel de aplicaciones, existen antecedentes de control de exoesqueletos basado en intención mediante sEMG para asistencia y rehabilitación, como el control de un exoesqueleto de rodilla, lo cual ilustra el puente directo entre intención estimada y lazo de control [13]. De manera complementaria, enfoques de HRI que incorporan interfaces sEMG y retroalimentación táctil proponen esquemas más centrados en el usuario, resaltando la importancia de la percepción y la participación activa en la rehabilitación [4].

En el mismo contexto, trabajos de aprendizaje de intención para control de asistencia con exoesqueletos portables muestran que no basta con reconocer las intenciones, sino que es necesario integrar la intención en políticas que modulen la asistencia sin imponer movimiento, favoreciendo la cooperación humano-robot [5]. Adicionalmente, propuestas recientes que fusionan EEG-EMG para un control adaptativo refuerzan la pertinencia de usar un enfoque multimodal cuando se busca obtener una asistencia más inteligente y sensible para el usuario [9].

Con estos antecedentes, queda claro que el algoritmo por sí solo no define el éxito del sistema, sino que el protocolo experimental y la sincronización multimodal determinan qué tan replicable y generalizable será el sistema. Por esto, el siguiente apartado se centra en protocolos de adquisición.

Robots de asistencia y rehabilitación para miembro superior

Los robots para rehabilitación y asistencia del miembro superior pueden agruparse, de forma general, en dispositivos tipo *end-effector* y en exoesqueletos. En particular, los exoesqueletos buscan acompañar la cinemática del usuario mediante estructuras articuladas alineadas con los segmentos corporales, lo cual impone retos de diseño por la complejidad biomecánica del miembro superior. Se ha reportado que el miembro superior involucra una gran cantidad de grados de libertad (DOF, por sus siglas en inglés, *degrees of freedom*), asociados al complejo del hombro, codo y muñeca, donde el hombro concentra una parte importante de la complejidad [25]. Esta alta dimensionalidad repercute en la necesidad de mecanismos compatibles con el rango de movimiento, la ergonomía y el acoplamiento físico, así como en estrategias de control capaces de adaptarse a variabilidad intersujeto y a cambios en la ejecución motora [26].

Desde la perspectiva del diseño mecánico, se han documentado esfuerzos para desarrollar exoesqueletos orientados específicamente a la rehabilitación del hom-

bro, reconociendo que el control de este segmento es crítico para tareas funcionales y que existen limitaciones prácticas en soluciones comerciales, tales como costo y falta de adecuación a medidas antropométricas de poblaciones específicas [27, 26]. Por ejemplo, se ha descrito el diseño de un prototipo de exoesqueleto de hombro dirigido a población adulta mexicana, cuya propuesta considera tres movimientos básicos del hombro y explora su desempeño mediante simulaciones cinemáticas y evaluación estructural, destacando además que la definición de las tareas de rehabilitación y su traducción a un mecanismo físicamente compatible constituyen una parte central del reto de ingeniería [27]. Asimismo, se reportan rangos de movimiento objetivo y restricciones ligadas tanto al diseño como a las condiciones mecánicas y a la posición anatómica inicial, lo cual ejemplifica la necesidad de delimitar con claridad el conjunto de movimientos asistidos y el contexto de uso [27].

En conjunto, estos hallazgos sustentan que, aunque existe una motivación fuerte por cubrir múltiples DOF del miembro superior, en entornos experimentales y de desarrollo incremental suele ser conveniente priorizar subconjuntos de movimiento, es decir, un DOF o un plano principal, para asegurar la alineación mecánica y seguridad, el control estable en presencia de variabilidad humana, y una trazabilidad en la evaluación del desempeño del sistema.

1.1.6. Síntesis de los antecedentes

Para finalizar esta primera sección, y como resumen, los antecedentes revisados permiten sentar las siguientes bases:

1. El reconocimiento de intención es un componente clave para exoesqueletos y robots de rehabilitación [2, 3].
2. Las señales de EEG y sEMG aportan información complementaria, y la fusión tiende a mejorar estabilidad frente a ruido y variabilidad [8, 17, 10, 9].

3. La implementación en tiempo real obliga a controlar la latencia y la confiabilidad temporal con estrategias asíncronas o por estados [18, 19].
4. El reconocimiento debe integrarse con un control de interacción seguro para evitar respuestas abruptas o peligrosas [7].
5. Los exoesqueletos para rehabilitación/asistencia de miembro superior, específicamente de hombro, concentran una gran complejidad biomecánica, por lo que suele abordarse de forma incremental iniciando con pocos DOF [26, 27].
6. Es recomendable un protocolo multimodal para lograr una buena generalización y evaluación realista [6].

1.2. Justificación

A nivel mundial, las condiciones neurológicas y musculoesqueléticas que afectan la movilidad representan una carga creciente para los sistemas de salud y rehabilitación. En particular, el accidente cerebrovascular constituye una de las principales causas de muerte y discapacidad: en 2021 se estimaron 93.8 millones de casos prevalentes y 11.9 millones de casos nuevos de accidente cerebrovascular en el mundo. De manera más amplia, la necesidad de tecnologías de asistencia también es considerable; la Organización Mundial de la Salud estima que 2.5 mil millones de personas requieren uno o más productos de asistencia, cifra que podría aumentar a 3.5 mil millones para 2050 debido al envejecimiento poblacional y al incremento de enfermedades no transmisibles [28, 29].

En México, esta problemática también es relevante. De acuerdo con datos de la Secretaría de Salud, en 2021 el ictus o enfermedad vascular cerebral ocasionó 37,453 defunciones y se ubicó como la séptima causa de muerte en la población general. Asimismo, la ENADID 2023 reportó que 8.9 millones de personas en

México presentaban discapacidad, equivalente al 6.8 % de la población. Estos datos evidencian la necesidad de desarrollar tecnologías de asistencia y rehabilitación que contribuyan a mejorar la autonomía, la seguridad y la participación activa de personas con alteraciones motoras [30, 31, 32].

La rehabilitación y asistencia motora de la extremidad superior continúan siendo un reto tecnológico y clínico debido a la complejidad del movimiento humano, la variabilidad entre usuarios y la necesidad de interacción segura cuando un dispositivo robótico aplica fuerzas sobre el cuerpo. En este contexto, los exoesqueletos y robots de asistencia han mostrado potencial para apoyar tareas funcionales y terapias de rehabilitación; sin embargo, su utilidad depende de que el sistema sea capaz de interpretar de manera confiable la intención del usuario y traducirla en comandos adecuados de control [3, 4, 5]. Esto es especialmente relevante en escenarios de rehabilitación física y neurológica, donde la activación muscular residual puede ser limitada o altamente variable, y donde resulta útil complementar la información periférica con indicadores corticales [16].

A pesar del avance del estado del arte, persiste una brecha entre los desempeños reportados en condiciones controladas y la operación robusta en escenarios reales. En primer lugar, algunos enfoques dependen de una sola modalidad de señal, por lo que pueden degradarse ante ruido, fatiga, cambios de colocación de sensores o variabilidad entre usuarios [12, 11, 22]. En segundo lugar, una parte importante de los sistemas se valida principalmente fuera de línea, lo que puede no reflejar efectos temporales relevantes como latencia, transiciones de fase, acumulación de falsas activaciones y estabilidad entre ventanas consecutivas [18, 19]. En tercer lugar, no todos los enfoques se integran de forma completa con una capa de control robótico bajo restricciones de seguridad, comunicación y operación en tiempo real [6, 7].

Por lo anterior, esta tesis propone una arquitectura multimodal de detección de intención motora orientada a operación en tiempo real e integración con un

exoesqueleto de miembro superior. La propuesta no se limita al desarrollo de un clasificador aislado, sino que integra adquisición de señales EEG, sEMG e IMU, procesamiento por ventanas, fusión de características, clasificación jerárquica L1–L2, filtrado temporal mediante una máquina de estados, generación de referencias suaves y comunicación con un controlador embebido. De esta forma, el sistema busca cerrar el flujo entre señales del usuario, decisión de intención y movimiento asistido, manteniendo criterios de estabilidad temporal y seguridad durante la interacción.

La fusión multimodal se justifica por la complementariedad entre señales. La EEG aporta información cortical asociada con la preparación y planificación motora, aunque es sensible a artefactos y variabilidad entre usuarios y sesiones [14, 22, 20]. La sEMG proporciona información periférica relacionada con la activación muscular, pero puede verse afectada por fatiga, debilidad, cambios de impedancia y recolocación de electrodos [12, 11]. De manera complementaria, la IMU aporta evidencia cinemática y temporal del movimiento, útil para robustecer la decisión en escenarios dinámicos [21, 6]. Por ello, combinar estas modalidades permite aprovechar fuentes de información complementarias y reducir la dependencia de una sola señal durante la detección de intención [17, 10].

La decisión de centrar el desarrollo en el miembro superior derecho responde a un criterio práctico de delimitación experimental y de diseño. Al restringir el sistema a un único miembro y a un grado de libertad principal, se reduce la variabilidad de acoplamiento físico y de configuración del dispositivo, facilitando la estandarización del protocolo de adquisición, la instrumentación y la evaluación comparativa del desempeño. Además, dado que el hombro concentra una alta complejidad biomecánica y es un punto crítico en exoesqueletos de miembro superior, iniciar con un movimiento principal en este segmento permite avanzar de forma incremental hacia soluciones de mayor dimensionalidad, manteniendo requisitos

razonables de seguridad, ergonomía y control [26, 27].

En robótica de asistencia, la utilidad práctica del reconocimiento de intención depende de su integración con un esquema de control que garantice seguridad y comportamiento estable. Diversos enfoques de interacción humano-exoesqueleto y propuestas de control basadas en intención resaltan la necesidad de combinar estimación de intención con estrategias de control, límites de acción y mecanismos de tolerancia a incertidumbre [4, 5, 33]. En particular, los enfoques de impedancia con acciones acotadas refuerzan que, en lazo cerrado, el sistema debe operar dentro de límites seguros y con estabilidad ante incertidumbre [7]. Esto justifica que la arquitectura propuesta contemple no solo la clasificación de intención, sino también su comunicación al controlador embebido y su traducción en referencias articulares suaves para el exoesqueleto.

Una contribución clave de esta tesis es consolidar un flujo de evaluación coherente con el despliegue real del sistema HMI-exoesqueleto. La evaluación fuera de línea es necesaria para comparar algoritmos y ajustar hiperparámetros, pero puede sobreestimar el desempeño cuando el preprocesado o la segmentación no reflejan condiciones reales. La evaluación en línea permite reproducir ventanas secuenciales, cuantificar retardo efectivo, detectar errores de transición y observar acumulación de falsas activaciones. Finalmente, la operación en tiempo real impone restricciones estrictas de cómputo, sincronización y comunicación, debido a que la salida del clasificador puede traducirse en acciones físicas del exoesqueleto [6, 18, 19]. Por esta razón, el sistema no se limitó a una validación por simulación, sino que se integró en una plataforma experimental compuesta por una computadora de procesamiento (PC) de procesamiento, comunicación UDP, un controlador embebido cRIO-9067 con LabVIEW Real-Time y un exoesqueleto de miembro superior.

De esta manera, la relevancia de la tesis radica en integrar, dentro de un

mismo marco experimental y de implementación, elementos que frecuentemente se reportan por separado: adquisición multimodal, procesamiento de señales, fusión de información, clasificación orientada a tiempo real, comunicación con un controlador embebido y generación de movimiento asistido en una plataforma robótica. Aunque este trabajo no pretende presentar un sistema clínico terminado, sí busca dejar una base funcional para futuras etapas de validación, calibración y adaptación con usuarios. En el contexto de rehabilitación y asistencia, este tipo de arquitectura puede contribuir al desarrollo de sistemas más personalizados, seguros y centrados en la participación activa del usuario [3, 8, 9].

1.3. Hipótesis

El sistema multimodal propuesto, basado en señales EEG, sEMG e IMU y en una clasificación jerárquica L1–L2, es capaz de detectar en línea la intención de movimiento del usuario para tareas de flexión/extensión de hombro, alcanzando una precisión ponderada y una sensibilidad ponderada iguales o superiores a 0.80, con una latencia media posterior al cierre de ventana menor a 100 ms, manteniendo así un desempeño compatible con un escenario de asistencia robótica en tiempo real.

1.4. Objetivo general

Desarrollar un sistema de detección de la intención motora del usuario para robots de asistencia, procesando la información proveniente de diversos sensores y empleando algoritmos de inteligencia artificial.

1.5. Objetivos particulares

1. Integrar sensores de actividad bioeléctrica y cinemática (EEG, sEMG e IMU) en un sistema robótico de asistencia, incluyendo adquisición, registro y sincronización.
2. Desarrollar el flujo de trabajo del procesamiento y fusión multimodal para la segmentación, extracción y selección de características para clasificar la intención del usuario.
3. Implementar y evaluar un algoritmo de inteligencia artificial para detectar la intención del usuario a partir de señales multimodales en tareas de interacción humano-robot.
4. Validar experimentalmente el sistema mediante simulaciones y pruebas con usuarios, cuantificando el desempeño y métricas temporales.

1.6. Estructura de la tesis

La presente tesis se organiza en cinco capítulos principales. En el Capítulo 1 se presenta la introducción general del trabajo, incluyendo los antecedentes del problema, la justificación, la hipótesis y los objetivos que guían el desarrollo del sistema propuesto. Este capítulo establece el contexto de la detección de intención motora en interacción humano-robot y delimita la motivación del estudio.

En el Capítulo 2 se describe la metodología empleada para el desarrollo del sistema. Se detallan el protocolo de adquisición multimodal de señales, el procesamiento de EEG, sEMG e IMU, la extracción y selección de características, el entrenamiento de los clasificadores, la plataforma experimental, la integración con el exoesqueleto y el análisis estadístico utilizado para evaluar el desempeño del sistema.

En el Capítulo 3 se presentan los resultados obtenidos durante las distintas etapas del proyecto. Primero se reportan los resultados de optimización y selección del modelo; posteriormente, se muestran las pruebas de validación progresiva en simulación y, finalmente, los resultados experimentales en tiempo real con el sistema HMI-exoesqueleto integrado.

En el Capítulo 4 se discuten los hallazgos principales del trabajo, considerando las implicaciones del diseño del modelo, la fusión multimodal, la validación progresiva, el desempeño experimental, la latencia, la estabilidad de las decisiones y la comparación con la literatura. Asimismo, se analizan los alcances estadísticos de los resultados y su relevancia para aplicaciones futuras en asistencia robótica.

En el Capítulo 5 se presentan las conclusiones generales de la tesis, las contribuciones técnicas del trabajo, sus principales limitaciones y las líneas de trabajo futuro. Finalmente, se incluyen apéndices con información complementaria sobre parámetros del controlador, reglas de la máquina de estados, banco CSP, características utilizadas y análisis estadísticos adicionales.

02

Metodología

En este Capítulo se describe la metodología utilizada para el desarrollo del sistema de detección de intenciones de movimiento, que abarca desde la etapa de planificación hasta la integración de los distintos módulos para el funcionamiento en lazo cerrado y en tiempo real.

En general, el flujo de trabajo se dividió en dos fases principales: primero, una etapa *offline*, enfocada en el diseño del protocolo experimental, la adquisición de las señales, el procesamiento de las mismas, el entrenamiento de los clasificadores y la implementación y prueba del controlador para la plataforma experimental; y segundo, la etapa en tiempo real, donde se unieron los modelos entrenados en un flujo de trabajo con la plataforma experimental, y de esta manera, se generaron movimientos asistidos a partir de la intención continua del usuario.

La Figura 2.1 presenta un diagrama de flujo correspondiente al trabajo de tesis, donde se resumen gráficamente las relaciones entre las distintas fases del proyecto descritas en este Capítulo.




Figura 2.1. Diagrama de flujo general del sistema HMI centrado en detección de intenciones.

2.1. Diseño experimental y protocolo de adquisición de señales

El protocolo de adquisición de señales constituye la base experimental sobre la cual se entrenó, evaluó e integró el sistema de detección de intención propuesto. Debido a la naturaleza multimodal del proyecto, el protocolo fue diseñado para garantizar condiciones reproducibles de medición, una estructura temporal clara de ejecución de tareas y un registro consistente de eventos, permitiendo que los datos obtenidos sean comparables entre sujetos y sesiones. Cabe destacar que la etapa de adquisición fue concebida para abarcar tres grados de libertad del miembro superior derecho, con el fin de construir una base de datos amplia; sin embargo, para el desarrollo y validación presentados en esta tesis se priorizó el análisis de un solo grado de libertad, correspondiente al movimiento de flexión y extensión de hombro, con el propósito de consolidar el procesamiento, la clasificación y la integración en tiempo real antes de extender el sistema a tareas más complejas. Es importante resaltar que este protocolo (CEI-UASLP/16-2025) fue revisado y aprobado por el comité de ética de la Facultad de Medicina de la UASLP (CONBIOETICA-24-CEI-001-20220119).

Diseño del estudio

El protocolo experimental propuesto tuvo como objetivo adquirir señales de EEG, sEMG e IMU, durante la ejecución e imaginación motora de movimientos de miembro superior derecho, con el fin de entrenar y validar modelos de detección de intención de movimiento para su integración en un sistema robótico de asistencia.

El estudio se dividió en tres bloques de movimiento independientes, cada uno asociado a un grupo muscular específico del miembro superior derecho:

1. Flexión/extensión de codo,

2. Flexión/extensión de hombro y
3. Rotación medial/lateral de hombro.

Durante los tres bloques se realizó un registro multimodal y sincronizado de las señales antes mencionadas, bajo condiciones controladas de carga y retroalimentación auditiva. Esta organización modular por bloques permitió optimizar la calidad del registro muscular, debido a las restricciones en el número de canales disponibles para la obtención de la señal de sEMG; además, facilitó el análisis segmentado por tipo de movimiento y grupo muscular. Además de la adquisición inicial para entrenamiento y desarrollo del modelo, se contempló una etapa final de validación experimental con el sistema HMI-exoesqueleto integrado. En dicha etapa se introdujeron variaciones controladas de visión y carga externa, con el propósito de evaluar la robustez del sistema ante cambios sensoriales y mecánicos de la tarea. De esta manera, el diseño experimental no solo buscó obtener una base de datos multimodal reproducible, sino también analizar el comportamiento del sistema bajo condiciones más cercanas a una operación asistiva real. Todas las adquisiciones mencionadas en esta tesis se llevaron a cabo en el Laboratorio de Robótica de la Facultad de Ciencias, Universidad Autónoma de San Luis Potosí (UASLP).

Participantes

Se reclutaron 15 voluntarios sanos, específicamente diestros, con edades entre 18 y 30 años. El tamaño de muestra fue seleccionado con base en estudios previos de BCIs no invasivas, donde combinaciones similares de número de sujetos y ensayos han demostrado ser suficientes para entrenar y validar modelos de clasificación con precisión aceptable [14, 8, 24, 18]. Con este número de voluntarios se pretendió equilibrar la carga experimental con la necesidad de obtener un conjunto de datos robusto y representativo.

La participación se organizó en dos etapas. En la adquisición inicial participaron 15 voluntarios, cuyas señales se utilizaron para construir la base de datos, desarrollar el procesamiento y entrenar los clasificadores. Posteriormente, en la validación experimental final participaron 10 personas: cinco pertenecientes al grupo inicial de 15, denominadas sujetos conocidos porque sus registros habían formado parte del conjunto de entrenamiento, y cinco participantes adicionales, denominados sujetos desconocidos porque no habían aportado datos previamente al modelo. Por tanto, el estudio incluyó un total de 20 participantes únicos: 15 en la adquisición inicial y cinco participantes nuevos incorporados exclusivamente para evaluar la generalización del sistema.

Antes de iniciar la adquisición de señales, cada participante recibió una explicación verbal y escrita sobre los objetivos del estudio, los procedimientos experimentales, la instrumentación utilizada, la duración aproximada de cada sesión, los posibles riesgos o molestias, el manejo confidencial de los datos y su derecho a retirarse del estudio en cualquier momento sin repercusiones. Posteriormente, los voluntarios que aceptaron participar firmaron el consentimiento informado aprobado por el comité de ética correspondiente. El formato utilizado se incluye en el Apéndice A.

Los criterios de inclusión fueron los siguientes:

- Adultos jóvenes de entre 18 y 30 años.
- Dominancia manual derecha, con el fin de estandarizar la lateralización de la actividad motora cortical.
- Ausencia de antecedentes de trastornos neurológicos, musculares o dermatológicos relevantes para el estudio.
- Ausencia de lesiones cutáneas o irritaciones en las zonas destinadas para la

colocación de electrodos, específicamente en brazo derecho y cuero cabelludo.

- Aceptación voluntaria para participar en el estudio mediante la firma del consentimiento informado.

Los criterios de no inclusión fueron:

- Personas fuera del intervalo de edad establecido.
- Personas zurdas o con dominancia manual no claramente derecha.
- Personas con antecedentes reportados de enfermedades neurológicas, musculares o dermatológicas en las zonas de colocación de electrodos.
- Personas bajo medicación psiquiátrica o neuromuscular.
- Personas que no hubieran dormido al menos 6 horas la noche previa a la sesión experimental.
- Personas que hubieran consumido alcohol o drogas durante las 12 horas previas a la sesión.
- Personas que no aceptaran participar voluntariamente o que no firmaran el consentimiento informado.

Los criterios de exclusión fueron:

- Participantes que solicitaran retirarse del estudio en cualquier momento.
- Participantes que presentaran fatiga excesiva, dolor, incomodidad persistente, irritación cutánea o alguna molestia durante la sesión experimental.

- Registros con fallas importantes de adquisición, pérdida de sincronización entre dispositivos o ruido excesivo que impidiera el procesamiento confiable de las señales.
- Incumplimiento de las indicaciones del protocolo durante la adquisición, cuando esto afectara la validez del registro.

Cada voluntario participó en dos sesiones experimentales en días distintos, con un mínimo de 24 horas entre cada adquisición y una duración aproximada de 40 minutos por sesión, lo que permitió evaluar la reproducibilidad intra- e inter-sujeto.

Equipamiento

Para la adquisición de señales se empleó el siguiente equipamiento:


- **MindRove ARC para señal de EEG:** Se empleó un dispositivo MindRove ARC (MindRove Ltd., Budapest, Hungría), inalámbrico, con seis canales principales y dos auxiliares, conformado por electrodos semi-secos, Figura 2.2(a). Dichos sensores cubren la región cortical sensoriomotora, equivalente a C1-C6 del sistema internacional 10-20. La frecuencia de muestreo se fijó en 500 Hz, lo que proporcionó una resolución suficiente para analizar la actividad en las bandas mu y beta asociadas a la corteza motora [34].
- **Biosignalsplux para señal de sEMG concentrada:** Se utilizó un sistema BioSignalsPlux (PLUX Wireless Biosignals S.A., Lisboa, Portugal), modular portátil con frecuencia de muestreo de 1000 Hz, Figura 2.2(b). La versión disponible en el laboratorio registra dos canales diferenciales de sEMG de manera simultánea. Se utilizaron electrodos superficiales autoadhesivos colocados sobre los músculos de interés en cada bloque experimental [35].

- **MYO Armband para señal de sEMG y registro cinemático:** Se utilizó un dispositivo MYO Armband (Thalmic Labs Inc., Kitchener, ON, Canadá), una banda de adquisición inalámbrica que integra sensores de sEMG, a 200 Hz, además de contar internamente con unidades cinemáticas para la obtención de señales de IMU, a 50 Hz, Figura 2.2(c). Se utilizó principalmente para registrar la cinemática del segmento de miembro superior, y complementar la información muscular [36].
- **Material adicional:** Se utilizó una pesa de 0.88 kg para simular la condición de movilidad reducida, Figura 2.2(d), gel conductor, mobiliario ergonómico del laboratorio y equipo de cómputo para registro, almacenamiento y respaldo de los datos.


Es importante señalar que previamente se han utilizado estos dispositivos en la literatura en aplicaciones de BCIs, registro de señales musculares y control de exoesqueletos [37, 38, 39].

Preparación de las áreas corporales para la adquisición

Previo a la colocación de los sensores, se prepararon las áreas corporales destinadas al registro de señales para mejorar la calidad de contacto y reducir artefactos. Para EEG, se verificó que la región central del cuero cabelludo estuviera libre de elementos que dificultaran el contacto de los electrodos semi-secos, y se ajustó la diadema MindRove ARC sobre la región sensoriomotora correspondiente a C1–C6. Para sEMG, se identificaron las zonas musculares de interés en cada bloque experimental y se limpió superficialmente la piel antes de colocar los electrodos, con el propósito de mejorar la adherencia y reducir la impedancia de contacto. Finalmente, el MYO Armband se colocó de forma estable sobre el miembro superior derecho, procurando comodidad y evitando restricciones al movimiento.



(a) MindRove ARC.



(b) Biosignalsplux.



(c) MYO Armband.



(d) Pesa adicional.

Figura 2.2. Dispositivos y material utilizado durante la adquisición de señales.

Bloques de movimiento y selección de músculos


El protocolo de adquisición contempló tres bloques experimentales, uno por cada grupo de movimiento del miembro superior derecho. En todos los bloques se mantuvo el registro de EEG sobre la región sensoriomotora mediante los canales centrales C1–C6, así como el uso del MYO Armband en el miembro superior derecho, conservando la misma orientación y posición relativa entre participantes y sesiones. Debido a que el sistema Biosignalsplux disponible permitía registrar dos canales diferenciales de sEMG de manera simultánea, la colocación de estos electrodos se ajustó según el bloque experimental. La referencia del sistema Biosignalsplux se colocó en la región del codo durante todos los bloques. La Tabla 2.1 resume la configuración utilizada.

Tabla 2.1. Bloques de movimiento y colocación de electrodos de sEMG del sistema Biosignalsplux.


Bloque	Movimiento evaluado	Colocación de sEMG Biosignalsplux
Bloque 1	Flexión/extensión de codo	Deltoides anterior y deltoides posterior. Referencia en codo.
Bloque 2	Flexión/extensión de hombro	Deltoides anterior y deltoides posterior. Referencia en codo.
Bloque 3	Rotación medial/lateral de hombro	Subescapular y pectoral mayor, o músculos equivalentes accesibles. Referencia en codo.

Nota. En todos los bloques se registró EEG con la misma configuración de canales centrales C1–C6. Asimismo, el MYO Armband se colocó en el miembro superior derecho manteniendo la misma orientación y posición relativa entre participantes y sesiones, registrando sEMG multicanal e IMU.


El registro de sEMG se organiza en bloques, debido a la presente limitación de canales posibles a usar durante la adquisición simultánea del Biosignalsplux utilizado. De esta forma, en lugar de distribuir pocos electrodos en muchos músculos, se prioriza la captura de señales en músculos más relevantes para cada movimiento




(a) Flexión/extensión, vista anterior.



(b) Flexión/extensión, vista posterior.



(c) Rotación de hombro, vista anterior.



(d) Rotación de hombro, vista posterior.

Figura 2.3. Configuraciones de colocación de electrodos para la adquisición de señales de sEMG según el bloque experimental. (a) y (b) corresponden a los bloques de flexión/extensión de hombro y codo; (c) y (d) corresponden al bloque de rotación medial/lateral de hombro.

solicitado, las configuraciones de colocación empleadas para el registro de sEMG se muestran en la Figura 2.3.

La colocación de los electrodos de sEMG se ajustó según el bloque de movimiento evaluado. En los bloques de flexión/extensión de codo y flexión/extensión de hombro se utilizó una configuración específica, mientras que en el bloque de rotación medial/lateral de hombro se modificó la colocación hacia músculos relevantes para dicho movimiento. Por esta razón, en la configuración correspondiente a un bloque de rotación puede observarse un electrodo no conectado al sistema de adquisición; dicho electrodo pertenecía a la configuración utilizada en los bloques de flexión/extensión y no fue utilizado como canal activo durante el bloque de rotación, y viceversa.

Adicionalmente, el brazalete MYO Armband se colocó en todos los participantes manteniendo la misma orientación y posición relativa sobre el miembro superior derecho, procurando contacto estable de sus electrodos con la piel y evitando restricciones al movimiento.

Estructura temporal de los ensayos

Cada ensayo estuvo compuesto por cinco fases temporales secuenciales, con una duración total de 8 segundos por ciclo:

1. **Alerta (0-1 s):** El participante recibía una señal auditiva que indica el inicio del ensayo y el tipo de movimiento que deberá ejecutar e imaginar.
2. **Preparación (1-3 s):** Es en este intervalo en el que el sujeto preparaba mentalmente el movimiento indicado, sin realizar aún el desplazamiento articular.
3. **Ejecución e imaginación (3-5 s):** Aquí, el participante ejecutaba el movimiento solicitado de forma controlada y, simultáneamente, mantenía la

imaginación motora del mismo, procurando minimizar el desplazamiento físico.

4. **Mantenimiento (5-7 s):** Se mantenía la posición indicada y el estado de imaginación, lo que permitía observar la actividad sostenida asociada a la contracción muscular y a la representación mental del movimiento.
5. **Retorno a reposo (7-8 s):** Finalmente, el sujeto regresaba a la posición inicial, y permanecía en reposo hasta el siguiente ensayo.

La estructura de estas 5 fases permitió segmentar posteriormente las señales en ventanas bien definidas, alinearlas entre modalidades y facilitó los cálculos de las variables específicas para cada etapa del movimiento. La organización temporal de estas fases se resume gráficamente en la Figura 2.4.

Condición de movilidad reducida

Durante la ejecución de los ensayos se le pedía al participante sostener una carga externa de 0.88 kg con la mano derecha, con el fin de simular un escenario de movilidad reducida o esfuerzo aumentado [40, 41]. Esta carga añadida:

- Incrementaba el esfuerzo requerido para ejecutar el movimiento.
- Modificaba la cinemática y los patrones de activación muscular.
- Permitía explorar cómo se alteraba la actividad cortical y muscular bajo condiciones de mayor demanda.

Se seleccionó el valor de la carga extra equilibrando entre la generación de un esfuerzo perceptible y el mantener la seguridad y comodidad en voluntarios sanos. Además, se intercalaban periodos de descanso entre bloques para evitar la sobrecarga muscular.

Preparación del participante y condiciones de registro

Cada sesión iniciaba con una fase de preparación para el participante; se le explicaba el procedimiento y se solucionaban preguntas. Después, se confirmaba el cumplimiento de los criterios de inclusión (sueño adecuado, ausencia de alcohol/-drogas antes de la sesión, etc.). Posteriormente, se limitaban las zonas de registro para una buena colocación de los electrodos. Finalmente, se colocaba la diadema de adquisición de señales de EEG, los electrodos para las señales de sEMG y el brazalete MYO Armband.

Además, gran parte del tiempo de preparación del participante se invirtió en explicar la retroalimentación auditiva que se utilizaría durante la adquisición. Esto se debe a la decisión de emplear una condición controlada en la que los participantes mantuvieron los ojos cerrados, en lugar de utilizar estímulos visuales para seguir las indicaciones. Esta configuración redujo los artefactos por parpadeos y homogenizó el estado de atención entre ensayos, lo que mejoró la calidad de la señal de EEG. El uso de indicaciones auditivas proporcionaba marcadores temporales claros sin comprometer la concentración del participante [42].

Estas medidas buscaron reducir la variabilidad asociada con la atención y la demanda cognitiva de la tarea; sin embargo, el estrés, la motivación, la carga mental y la fatiga cognitiva no se cuantificaron mediante instrumentos específicos durante las sesiones.

Se utilizaron tonos a una frecuencia específica para cada indicación perteneciente al ensayo de movimiento. Con relación a la sección 2.1, para las primeras 3 indicaciones (alerta, preparación y ejecución) se utilizó un tono agudo (1500 Hz) o grave (400 Hz), con el objetivo de distinguir entre ejercer una flexión/rotación medial o una extensión/rotación lateral, respectivamente. Para las últimas dos indicaciones (mantenimiento y reposo) se generaron tonos neutros (1000 Hz) indistintamente.


Finalmente para la etapa de preparación, el participante permaneció sentado en una posición cómoda, con el brazo derecho libre para ejecutar las tareas. Se vigilaba constantemente la presencia de molestias, fatiga excesiva, ruido ambiental exagerado o cualquier situación que ameritara la interrupción del protocolo.

Cronograma de sesión y número de ensayos

Cada sesión tuvo una duración aproximada de 40 minutos y se organizó de la siguiente manera:

- Preparación inicial (explicación, limpieza, colocación de sensores): 10-15 min.
- Tres bloques de adquisición (uno por tipo de movimiento), cada uno con 40 ensayos, con una duración por bloque de aproximadamente 6 min, con periodos de descanso de 2 a 5 min entre bloques.

En total, cada participante contribuyó con dos sesiones independientes, con un mínimo de 24 horas entre cada sesión del mismo participante [24], con el fin de evaluar variaciones inter- e intra-sujeto. La misma Figura 2.4 integra además la duración aproximada de cada bloque, los descansos entre bloques y la repetición del protocolo en dos sesiones por participante.



Registro, sincronización y procesamiento básico

Las señales de EEG, sEMG y cinemática se adquirieron de forma simultánea durante cada sesión experimental, buscando una alineación temporal precisa entre modalidades desde el momento del registro. Para esto, se implementó una arquitectura de adquisición basada en tres procesos en Python. Primero, se utilizó un módulo principal (*main*) de control y adquisición del MindRove ARC y el Biosignalsplux, un módulo *sender* dedicado al brazalete MYO Armband y un módulo *receiver* que integró la información del MYO en el mismo esquema temporal que los demás dispositivos.

El módulo principal (*main acquisition*) se ejecutó en un entorno de Python 3.10 [43], mientras que el segundo proceso para la adquisición del *Myo sender*, se ejecutó en un entorno independiente de Python 3.9 [44]; este segundo proceso empaquetaba los datos y los transmite mediante comunicación UDP (User Datagram Protocol) al proceso donde corre el entorno principal. Finalmente, el módulo *receiver*, también en Python 3.10, recibía la información en el puerto UDP correspondiente y se encargaba de convertir los paquetes enviados por el *sender* a datos temporales sincronizados.

Con esta arquitectura emisor–receptor–módulo principal se resolvió la compatibilidad de versiones de Python entre dispositivos, sin perder sincronización.

Finalmente, durante la adquisición se aplicaron los siguientes filtros y procedimientos:

- Para el EEG por el MindRove ARC, se aplicó un filtro notch a 50/60 Hz para eliminar el ruido de línea. Además de un filtro Butterworth pasa-banda de 1 a 30 Hz de cuarto orden.
- Para el sEMG por el Biosignalsplux, durante la adquisición se aplicó un filtro pasa-banda de 10-450 Hz de tipo Butterworth de sexto orden. El sistema

incorpora además, un filtro analógico de protección y acondicionamiento previo.

- Sobre las señales del MYO Armband, este equipo ya realiza un procesamiento interno de las señales de sEMG antes de transmitir las, por lo que no se aplicaron filtros adicionales durante la adquisición. Las señales de acelerometría y giroscopio se registraron tal como las entregaba el dispositivo.

Una vez finalizada la sesión del bloque de adquisición, se consideró únicamente el segmento de señal comprendido entre el primer marcador de inicio de sesión y el final del último periodo de reposo, descartando cualquier dato previo o posterior al protocolo formal. Finalmente se guardaron las señales y la correspondencia de eventos en un archivo de tipo CSV (valores separados por comas), y un archivo de texto con los metadatos de la sesión.

Relación entre adquisición, simulaciones y validación experimental

El protocolo de adquisición descrito en esta sección se diseñó como la primera etapa de una estrategia de validación progresiva del sistema HMI-exoesqueleto. A partir de las señales adquiridas, sincronizadas y etiquetadas, se construyeron los conjuntos de datos utilizados para el procesamiento *offline*, el entrenamiento de los clasificadores, las simulaciones con señales pregrabadas y, posteriormente, la integración en tiempo real con la plataforma robótica.

De esta manera, la metodología siguió una secuencia incremental: primero se adquirieron datos multimodales bajo condiciones controladas; después se evaluó el flujo de procesamiento y clasificación sobre registros previamente adquiridos; posteriormente se probó la operación *online* con señales en vivo; luego se verificó la comunicación con el sistema embebido y el movimiento del exoesqueleto usando secuencias pregrabadas; y finalmente se realizó la validación experimental con

usuarios instrumentados, condiciones de visión/carga y operación en lazo cerrado.

La Tabla 2.2 resume la relación entre estas etapas.

Tabla 2.2. Relación entre el protocolo de adquisición y las etapas posteriores de simulación y validación experimental.

Etapa	Fuente de datos o señales	Propósito dentro del desarrollo
Adquisición multi-modal inicial	EEG, sEMG e IMU registrados en 15 voluntarios, dos sesiones por participante y tres bloques de movimiento por sesión.	Construir la base de datos para entrenamiento, procesamiento <i>offline</i> , extracción de características y evaluación inicial del modelo.
Simulación <i>offline</i> con base de datos	Registros previamente adquiridos y almacenados.	Verificar el flujo de sincronización, ventanao, extracción de características, clasificación jerárquica y generación de intención sin depender de señales en vivo ni del exoesqueleto.
Simulación <i>online</i> con sujeto	Señales EEG, sEMG e IMU adquiridas en vivo, sin conectar el exoesqueleto al usuario.	Evaluar el comportamiento temporal del procesamiento <i>online</i> , las decisiones consecutivas del clasificador y la estabilidad de la referencia generada en tiempo real.
Simulación con exoesqueleto en lazo cerrado	Secuencias de intención generadas desde datos pregrabados y enviadas al cRIO.	Probar la comunicación UDP, la máquina de estados, la generación de referencias y el movimiento del exoesqueleto antes de la validación final con usuario.
Validación experimental final	Señales en vivo de usuarios instrumentados, con el sistema HMI-exoesqueleto operando en tiempo real.	Evaluar el sistema integrado bajo condiciones controladas de visión y carga, comparando el desempeño entre sujetos conocidos por el algoritmo, cuyas señales formaron parte del entrenamiento, y sujetos desconocidos, correspondientes a nuevos participantes no incluidos previamente en el modelo.

Aspectos éticos y consentimiento informado

El protocolo se desarrolló de acuerdo con los principios de la Declaración de Helsinki y la normativa mexicana vigente para investigación en seres humanos. Además, dicho protocolo fue evaluado y aprobado por el comité de ética correspondiente.

Los datos se almacenaron de manera codificada, utilizando un indicador alfanumérico por participante. Únicamente el equipo de investigación tiene acceso a la correspondencia entre códigos y datos personales. Los resultados se utilizaron sin información que permitiese la identificación individual de los participantes.

2.2. Procesamiento de señales y extracción de características

El objetivo del procesamiento en esta sección fue transformar las señales crudas de EEG, sEMG e IMU adquiridas en el protocolo anterior, en vectores multimodales compactos, discriminatorios y sobre todo sincronizados, para su posterior uso por los clasificadores de intención motora. La selección inicial de características se realizó con base en tres criterios principales: su uso documentado en tareas de reconocimiento motor con EEG, sEMG o señales cinemáticas; su interpretación fisiológica o funcional dentro del proceso motor; y su viabilidad computacional para una implementación basada en ventanas y orientada a operación en tiempo real. Por ello, se combinaron descriptores temporales, espectrales, relativos a línea base y espaciales, con el propósito de representar información complementaria sobre actividad cortical, activación muscular y expresión cinemática. Para conseguir esto, en general, se automatizó la sincronización temporal de todos los canales, el ventaneo de las señales y el cálculo de las características específicas para cada modalidad, se implementó en Python 3.10 de 64 bits, [43] sobre Windows 11

(64-bit). La Figura 2.5 muestra el flujo de trabajo para esta subsección.

Con este flujo de trabajo y para cada ventana temporal de una sesión se obtuvieron:

- Un registro con los metadatos de inicio, final de la ventana, fase del protocolo, tipo de movimiento, clave del sujeto y sesión;
- Las características de EEG obtenidas sobre las bandas mu y beta;
- Características en el dominio del tiempo y en frecuencia de sEMG; y finalmente,
- Estadísticas del acelerómetro y giroscopio correspondientes a la señal de IMU.




Figura 2.5. Diagrama de bloques sobre la extracción de características.

Sincronización de señales y ventaneo

Las señales adquiridas por cada dispositivo se almacenaron de manera independiente en archivos CSV con sus respectivas columnas de tiempo. El *script* que interpretaba estos archivos, detectaba la columna de tiempo, la convertía en segundos, y corregía desplazamientos iniciales cuando era necesario, unificando así la escala temporal para todas las modalidades.

Como control de calidad adicional, se realizó una auditoría *offline* de consistencia entre las etiquetas del protocolo y la información registrada en las ventanas. Para ello, se identificaron ventanas potencialmente atípicas mediante indicadores derivados de la actividad muscular, la cinemática de IMU y el desacuerdo de clasificación bajo validación interna. Las ventanas señaladas se revisaron para detectar posibles ejecuciones contrarias a la instrucción, movimientos involuntarios, actividad durante reposo o fallas de etiquetado. Este procedimiento se utilizó como apoyo para la depuración de registros y no como una medición independiente del movimiento real del participante.

Las ventanas cuya inconsistencia pudo confirmarse con los registros disponibles se excluyeron antes de continuar con la construcción definitiva de la matriz de características.

Relación fisiológica y funcional de las ventanas de análisis

Una vez sincronizadas las señales y definidas las ventanas de análisis, cada ventana puede interpretarse como una observación temporal de distintas etapas del proceso motor. En el contexto del protocolo experimental, la indicación auditiva inicia una cadena de eventos que involucra atención al estímulo, preparación motora, ejecución o imaginación del movimiento, activación neuromuscular, expresión cinemática y retorno progresivo a reposo. Por esta razón, las características extraídas de EEG, sEMG e IMU se interpretaron como descriptores complementarios

de distintos niveles del proceso motor: cortical, muscular y mecánico.

La Figura 2.6 resume esta relación entre las fases del ensayo, los eventos fisiológicos esperados y las señales utilizadas por el sistema.

Procesamiento y características de la señal de EEG

Primero, las señales de EEG obtenidas de los 6 canales se sometieron al pre-procesado descrito en la sección 2.1, es decir, el filtrado de línea y pasa banda, luego se segmentaron según las ventanas definidas en la subsección anterior.

Para la reducción de artefactos oculares en EEG se aplicó un procedimiento de limpieza fuera de línea basado en análisis de componentes independientes (ICA, por sus siglas en inglés, independent component analysis). Previamente, la señal EEG fue filtrada en la banda de 1–40 Hz mediante un filtro Butterworth pasa banda de cuarto orden, con el propósito de conservar la actividad relevante para el análisis motor y mejorar la estabilidad de la descomposición. Posteriormente, se aplicó FastICA [45] con un número de componentes igual al mínimo entre el número de canales disponibles y 15, usando blanqueamiento con varianza unitaria, semilla aleatoria fija y un máximo de 1000 iteraciones.

La identificación de componentes oculares se realizó mediante un criterio automático basado en una referencia promedio del EEG; y la razón de potencia entre actividad lenta y actividad sensoriomotora, calculada como la potencia en 0.5–6 Hz respecto a la potencia en 8–30 Hz. Ambas medidas se combinaron mediante una puntuación robusta, ponderando 0.6 la correlación con actividad frontal y 0.4 la razón de potencia lenta. El componente con mayor puntuación fue excluido y la señal EEG fue reconstruida a partir de los componentes restantes. Este procedimiento permitió reducir contribuciones compatibles con artefactos oculares conservando la estructura multicanal de la señal para la posterior extracción de características.




Figura 2.6. Relación biomédica y funcional entre las fases del protocolo experimental, los eventos fisiológicos esperados y las señales EEG, sEMG e IMU utilizadas para la detección de intención motora.

Para cada ventana temporal, se calculó un conjunto de características espectrales, temporales y relativas a línea base a partir de los canales EEG preprocesados. La estimación espectral se realizó mediante el método de Welch, usando una longitud de segmento $N_{\text{seg}} = \min(256, N)$, donde N corresponde al número de muestras disponibles en la ventana. La potencia en cada banda se obtuvo integrando la densidad espectral de potencia mediante la regla trapezoidal:

$$P_{[f_1, f_2]} = \int_{f_1}^{f_2} \text{PSD}(f), df. \quad (1)$$

A partir de esta estimación se calcularon las potencias en la banda mu (8 – 13 Hz) y beta (13 – 30 Hz), denotadas como P_μ y P_β , respectivamente. Con ellas se obtuvieron tres características principales:

$$R_{\beta/\mu} = \frac{P_\beta}{P_\mu + \varepsilon}, \quad (2)$$

$$L_\mu = \log(P_\mu + \varepsilon), \quad (3)$$

$$L_\beta = \log(P_\beta + \varepsilon), \quad (4)$$

donde $\varepsilon = 10^{-12}$ se utilizó para evitar divisiones entre cero o logaritmos indefinidos. Estas características se incluyeron debido a que las bandas mu y beta se asocian con la dinámica sensoriomotora relacionada con preparación, ejecución e imaginación motora.

También se calculó la entropía espectral de Shannon en el intervalo de 8–30 Hz estimada a partir de la densidad espectral de potencia (PSD, por sus siglas en inglés, *power spectral density*) obtenida mediante Welch. Para ello, se normalizó la potencia espectral dentro de dicho intervalo como:

$$p_k = \frac{\text{PSD}(f_k)}{\sum_{j=1}^K \text{PSD}(f_j) + \varepsilon}, \quad (5)$$

y posteriormente se calculó:

$$H_{\text{esp}} = - \sum_{k=1}^K p_k \log(p_k + \varepsilon) \quad (6)$$

donde H_{esp} representa la entropía espectral de Shannon calculada sobre la distribución normalizada de potencia en el intervalo 8 – 30 Hz. Esta característica cuantifica la dispersión de la energía en el rango sensoriomotor: valores mayores indican una distribución espectral más dispersa, mientras que valores menores indican concentración de energía en frecuencias específicas.

Adicionalmente, se calcularon los parámetros de Hjorth, movilidad y complejidad, con el propósito de resumir propiedades temporales de la señal dentro de cada ventana. Sea $x[n]$ la señal EEG analizada, $\Delta x[n]$ su primera diferencia y $\Delta^2 x[n]$ su segunda diferencia. La movilidad se definió como:

$$M = \sqrt{\frac{\text{var}(\Delta x)}{\text{var}(x)}}. \quad (7)$$

La complejidad se calculó como:

$$C = \frac{\sqrt{\frac{\text{var}(\Delta^2 x)}{\text{var}(\Delta x)}}}{M}. \quad (8)$$

La movilidad resume cambios en la frecuencia dominante de la señal, mientras que la complejidad refleja variaciones en la forma de onda respecto a una señal sinusoidal simple.

Además, se estimó una característica global de energía en el rango 8 – 30 Hz mediante:

$$\log \text{var}_{8-30} = \log \left(\frac{P_{8-30}}{30-8} + \varepsilon \right), \quad (9)$$

donde P_{8-30} corresponde a la potencia integrada en el intervalo de 8 a 30 Hz. Esta medida se empleó como indicador compacto de energía oscilatoria en las bandas

relacionadas con actividad motora.

Finalmente, se calcularon medidas relativas respecto a una línea base. Para cada sesión, la línea base se estimó usando las ventanas etiquetadas como reposo, alerta o preparación. La desincronización/sincronización relativa en μ y β se calculó como:

$$ERD_{\mu} = \frac{P_{\mu} - \bar{P}_{\mu, \text{base}}}{\bar{P}_{\mu, \text{base}} + \varepsilon}, \quad (10)$$

$$ERD_{\beta} = \frac{P_{\beta} - \bar{P}_{\beta, \text{base}}}{\bar{P}_{\beta, \text{base}} + \varepsilon}. \quad (11)$$

De forma análoga, se calculó la actividad relativa en el rango 8 – 30 Hz como:

$$A_{\text{rel}, 8-30} = \frac{\exp(\log \text{var}_{8-30})}{\exp(\log \text{var}_{8-30})_{\text{base}} + \varepsilon} - 1. \quad (12)$$

Las características espectrales en las bandas μ y β , las medidas relativas a línea base y los patrones espaciales comunes se seleccionaron por su uso documentado para describir la modulación sensoriomotora y extraer información discriminativa durante la preparación, ejecución e imaginación motora [46, 47, 48].

En conjunto, estas características permitieron representar cada ventana EEG mediante información espectral, temporal y relativa a línea base, proporcionando una descripción compacta del estado corticomotor asociado con reposo, preparación y ejecución o imaginación motora.

Procesamiento y características de la señal de sEMG del Biosignalsplux

Las señales de sEMG obtenidas del sistema Biosignalsplux, tras el filtrado descrito en la adquisición, se segmentaron en las mismas ventanas temporales empleadas para el resto de las modalidades. Para cada ventana y cada canal se calcularon características en el dominio del tiempo y de la frecuencia, con el

propósito de representar tanto la intensidad de la activación muscular como la distribución espectral de la señal.

- **Dominio del tiempo:** sea $x[n]$ una señal de sEMG dentro de una ventana de N muestras. La raíz cuadrática media (RMS, por sus siglas en inglés, *root mean square*) se calculó como:

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N x[n]^2}. \quad (13)$$

El valor absoluto medio (MAV, por sus siglas en inglés, *mean absolute value*) se definió como:

$$MAV = \frac{1}{N} \sum_{n=1}^N |x[n]|. \quad (14)$$

La varianza se calculó mediante:

$$VAR = \frac{1}{N} \sum_{n=1}^N (x[n] - \bar{x})^2, \quad (15)$$

donde $\bar{x}$ representa el valor medio de la señal en la ventana. Finalmente, los cruces por cero (ZC, por sus siglas en inglés, *zero crossing*) se obtuvieron contando los cambios de signo entre muestras consecutivas:

$$ZC = \sum_{n=1}^{N-1} I(x[n]x[n+1] < 0), \quad (16)$$

donde $I(\cdot)$ es una función indicadora que toma el valor de 1 cuando la condición se cumple y 0 en caso contrario.

- **Dominio de la frecuencia:** la densidad espectral de potencia se estimó mediante el método de Welch, usando una longitud de segmento $N_{\text{seg}} =$

$\min(512, N)$. A partir de esta estimación, la potencia en bandas específicas se calculó mediante la integración trapezoidal definida en la Ecuación (1).

Para las señales de Biosignalsplux se consideraron las bandas 20 – 45 Hz, 55 – 95 Hz, 95 – 200 Hz y 200 – 350 Hz. La potencia de cada banda se expresó en escala logarítmica para reducir la influencia de valores extremos:

$$BP_{[f_1, f_2]} = \log_{10} (P_{[f_1, f_2]} + \varepsilon), \quad (17)$$

donde $\varepsilon = 10^{-12}$ se utilizó para evitar logaritmos indefinidos.

La frecuencia media (MNF, por sus siglas en inglés, *mean frequency*) se calculó como:

$$MNF = \frac{\sum_{k=1}^K f_k P_k}{\sum_{k=1}^K P_k}, \quad (18)$$

donde f_k es la frecuencia del bin espectral k y P_k es la potencia espectral correspondiente. La frecuencia mediana (MDF, por sus siglas en inglés, *median frequency*) se definió como la frecuencia que divide la potencia espectral acumulada en dos partes iguales:

$$\sum_{f_k \leq MDF} P_k = \frac{1}{2} \sum_{k=1}^K P_k. \quad (19)$$

Finalmente, se calculó la entropía espectral de Shannon a partir de la distribución normalizada de potencia espectral:

$$p_k = \frac{P_k}{\sum_{j=1}^K P_j + \varepsilon}, \quad (20)$$

A partir de esta distribución normalizada, la entropía espectral de Shannon

se calculó mediante la Ecuación (6).

Las características temporales y espectrales de sEMG, incluyendo RMS, MAV, varianza, cruces por cero, potencia por bandas, MNF, MDF y entropía espectral, se eligieron por su uso extendido para representar la intensidad, variabilidad y distribución frecuencial de la activación muscular con un costo computacional compatible con clasificación en tiempo real [10, 49].

De este modo, la combinación de parámetros temporales y frecuenciales permitió capturar tanto la intensidad de la activación muscular como la distribución espectral de la señal, con el fin de distinguir entre reposo y posibles contracciones asociadas a los movimientos de interés.

Procesamiento y características de la señal de sEMG e IMU del dispositivo MYO Armband

Para los canales de sEMG del MYO, se aplicaron los mismos cálculos de características temporales que el Biosignalsplux (RMS, MAV, varianza y ZC). Adicionalmente, se calcularon características espectrales (potencia en bandas, MNF, MDF y entropía espectral de Shannon). Debido a la frecuencia de muestreo del MYO Armband, las bandas de potencia consideradas fueron 20 – 45 Hz y 55 – 90 Hz. La estimación espectral se realizó con una longitud de segmento $N_{\text{seg}} = \min(512, N)$, donde N corresponde al número de muestras disponibles en la ventana.

En cuanto a los datos de IMU, se identificaron los ejes de aceleración y giroscopio, y se calcularon características estadísticas por eje y por magnitud vectorial. Para cada señal $x[n]$ dentro de una ventana de N muestras, se obtuvo la media:

$$\mu_x = \frac{1}{N} \sum_{n=1}^N x[n], \quad (21)$$

la desviación estándar:

$$\sigma_x = \sqrt{\frac{1}{N} \sum_{n=1}^N (x[n] - \mu_x)^2}, \quad (22)$$

y el rango:

$$R_x = \text{máx}(x) - \text{mín}(x). \quad (23)$$

Estas características se calcularon para los tres ejes del acelerómetro y del giroscopio. Además, para cada sensor se calculó la magnitud vectorial:

$$m[n] = \sqrt{x[n]^2 + y[n]^2 + z[n]^2}, \quad (24)$$

sobre la cual también se estimaron la media, la desviación estándar y el rango. De esta forma, las características de IMU permitieron representar la amplitud, variabilidad y cambios temporales del movimiento durante cada ventana.

Para estas señales se seleccionaron la media, desviación estándar, rango y magnitud vectorial, debido a que son descriptores de bajo costo computacional que permiten resumir la intensidad, variabilidad y dinámica global del movimiento dentro de cada ventana, y han sido utilizados como información cinemática en sistemas de reconocimiento de actividad y control de exoesqueletos [50].

Estas características capturaron la dinámica del movimiento del miembro superior e información complementaria a la actividad de sEMG y EEG, con el propósito de aportar evidencia cinemática para diferenciar movimientos con trayectorias similares, transiciones entre fases y variaciones en la ejecución motora.

Características espaciales complementarias de EEG mediante CSP

Para discriminar con mejor precisión entre movimientos de flexión y extensión, se incorporaron características espaciales de EEG mediante patrones espaciales comunes CSP. A diferencia de las características espectrales descritas previamente,

CSP busca encontrar proyecciones espaciales que maximicen la varianza de una clase y minimicen simultáneamente la varianza de la otra, lo que resulta útil en problemas binarios de EEG donde las clases presentan patrones espaciales distintos.

Sea $X_i \in \mathbb{R}^{T \times C}$ la matriz EEG de una ventana o ensayo, donde T representa el número de muestras temporales y C el número de canales. Para cada ventana se estimó una matriz de covarianza normalizada como:

$$\Sigma_i = \frac{X_i^T X_i}{\text{tr}(X_i^T X_i)}. \quad (25)$$

Posteriormente, se calcularon las matrices de covarianza promedio para las dos clases consideradas en L2, flexión y extensión:

$$\Sigma_F = \frac{1}{N_F} \sum_{i \in F} \Sigma_i, \quad \Sigma_E = \frac{1}{N_E} \sum_{i \in E} \Sigma_i. \quad (26)$$

El problema CSP se formuló como un problema generalizado de eigenvalores:

$$\Sigma_F w = \lambda (\Sigma_F + \Sigma_E) w, \quad (27)$$

donde w representa un filtro espacial y λ indica la proporción de varianza asociada con una clase respecto a la covarianza compuesta. Los filtros asociados con los eigenvalores más altos y más bajos permiten obtener componentes con máxima discriminación entre ambas clases.

Previo al cálculo de CSP, las señales EEG se filtraron en subbandas dentro del intervalo motor de 4 – 40 Hz. Para cada subbanda se estimó un criterio de selección basado en la diferencia entre clases y la consistencia de dicha diferencia. De forma general, para una subbanda b , se calculó una medida de diferencia entre clases D_b a partir de la separación entre las log-varianzas promedio de flexión y extensión:

$$D_b = |\overline{L_{F,b}} - \overline{L_{E,b}}|. \quad (28)$$

donde $\overline{L_{F,b}}$ y $\overline{L_{E,b}}$ representan las log-varianzas promedio de las clases flexión y extensión en la subbanda b . Además, se calculó una medida de consistencia W_b para favorecer subbandas con menor dispersión intraclase:

$$W_b = \frac{1}{\sigma_{F,b} + \sigma_{E,b} + \delta}, \quad (29)$$

donde $\sigma_{F,b}$ y $\sigma_{E,b}$ son las desviaciones estándar de las log-varianzas por clase, y δ es una constante pequeña para evitar divisiones entre cero. La puntuación final de cada subbanda se obtuvo como:

$$S_b = D_b W_b. \quad (30)$$

Las subbandas con mayor puntuación fueron seleccionadas para la extracción de características CSP. Para cada subbanda seleccionada, la señal filtrada se proyectó mediante los filtros espaciales CSP:

$$Z_b = X_b W_b^{\text{CSP}}, \quad (31)$$

y las características finales se obtuvieron como la log-varianza de las componentes proyectadas:

$$f_{b,j}^{\text{CSP}} = \log(\text{var}(Z_{b,j}) + \varepsilon), \quad (32)$$

donde $Z_{b,j}$ corresponde a la componente CSP j de la subbanda b , y $\varepsilon = 10^{-12}$ evita logaritmos indefinidos. En este trabajo, las características CSP se añadieron con el propósito de mejorar la separabilidad espacial entre flexión y extensión durante las fases de movimiento [8].

Construcción de la matriz de características y reducción de redundancias

A partir de las características definidas en las subsecciones anteriores, se estableció una interpretación fisiológica, anatómica o funcional de los principales grupos de descriptores utilizados. Esta relación no implica que cada característica constituya un biomarcador aislado de intención motora, sino que cada grupo resume información indirecta de un nivel del proceso motor. En este sentido, las características de EEG aportan información cortical asociada con atención, preparación, ejecución e imaginación motora; las características de sEMG describen la activación neuromuscular periférica; y las características de IMU representan la expresión cinemática del movimiento. Las Tablas 2.3–2.6 resumen esta relación.

Tabla 2.3. Relación entre las características de EEG y su interpretación fisiológica o funcional dentro del protocolo experimental. Parte I.

Característica	Proceso sentado	repre- sentado	Fase donde apor- ta más	Interpretación dentro del protocolo
Potencia en bandas μ y β	Actividad sensoriomotora.	oscilatoria	Preparación, ejecución e imaginación motora.	Las bandas μ y β se relacionan con la dinámica cortical sensoriomotora. Sus cambios de potencia permiten representar variaciones del estado cortical durante la preparación, ejecución o imaginación del movimiento.
Razón β/μ y log-potencia	Balance entre ritmos sensoriomotors.	espectral	Preparación y transición hacia movimiento.	Estas características resumen cambios relativos entre componentes oscilatorios del EEG, facilitando la comparación entre ventanas y reduciendo la dependencia de la amplitud absoluta de la señal.
ERD/ERS relativo a línea base	Modulación cortical respecto a una condición basal.	cortical	Preparación, ejecución e imaginación motora.	Permite cuantificar cambios relativos de potencia respecto al estado basal. Es útil para contrastar ventanas asociadas con intención o movimiento frente a ventanas de reposo o referencia.

Tabla 2.4. Relación entre las características de EEG y su interpretación fisiológica o funcional dentro del protocolo experimental. Parte II.

Característica	Proceso representado	Fase donde aporta más	Interpretación dentro del protocolo
Entropía espectral	Distribución de la energía en frecuencia.	Alerta, preparación y ejecución.	Resume si la energía del EEG se concentra en componentes específicos o se distribuye de forma más amplia dentro del rango analizado, aportando información sobre cambios globales del contenido espectral.
Parámetros de Hjorth	Variabilidad temporal y complejidad de la forma de onda.	Preparación, ejecución y retorno a reposo.	La movilidad y complejidad describen cambios en la dinámica temporal de la señal EEG, complementando las características espectrales durante las diferentes fases del ensayo.
CSP	Patrones espaciales discriminativos entre clases.	Ejecución e imaginación motora; clasificación L2.	El CSP busca combinaciones espaciales de canales que maximicen la separabilidad entre flexión y extensión, aprovechando diferencias en la distribución espacial de la actividad cortical asociada con cada clase.

En conjunto, estas características permitieron representar el proceso motor desde tres niveles complementarios: actividad cortical, activación neuromuscular y expresión cinemática. Por ello, su uso conjunto se interpretó como una aproximación multimodal en la que cada modalidad aporta información parcial y complementaria del estado funcional del participante durante cada ventana.

Una vez calculados todos los grupos de características, se construyó una matriz de características multimodal, en la que cada renglón correspondió a una ventana, y cada columna a una característica específica. Se etiquetaron también el inicio y fin de la ventana, la fase y el movimiento solicitado, el sujeto y finalmente la sesión, por medio de sus etiquetas en clave.

Antes de utilizar la matriz de características en la fase de entrenamiento de los

Tabla 2.5. Relación entre las características de sEMG y su interpretación fisiológica o funcional dentro del protocolo experimental.

Característica	Proceso representado	Fase donde aparece más	Interpretación dentro del protocolo
RMS, MAV y varianza	Intensidad de activación muscular.	Ejecución y mantenimiento.	Representan la magnitud de la actividad eléctrica muscular dentro de la ventana. Valores mayores suelen asociarse con mayor activación neuromuscular, reclutamiento de unidades motoras o esfuerzo muscular.
Cruces por cero	Cambios rápidos de polaridad y variabilidad temporal.	Transición reposo–movimiento y retorno a reposo.	Aportan información complementaria sobre la oscilación de la señal muscular y su contenido temporal, especialmente durante transiciones entre reposo, activación y movimiento.
Potencia por bandas	Distribución espectral de la activación muscular.	Ejecución, mantenimiento y condiciones con carga.	Permite describir cómo se reparte la energía de la sEMG en distintos intervalos de frecuencia, lo cual puede variar con el tipo de contracción, el esfuerzo y las condiciones de carga.
MNF y MDF	Frecuencia media y frecuencia mediana del espectro muscular.	Mantenimiento y contracción sostenida.	Estas características resumen el contenido frecuencial de la sEMG. Pueden reflejar cambios asociados con contracción sostenida, esfuerzo muscular o modificaciones espectrales relacionadas con fatiga.
Entropía espectral	Dispersión de la energía muscular en frecuencia.	Ejecución y mantenimiento.	Indica si la energía de la señal muscular se concentra en ciertas bandas o se distribuye de forma más amplia, complementando las medidas de amplitud y frecuencia.

Tabla 2.6. Relación entre las características de IMU y su interpretación funcional dentro del protocolo experimental.

Característica	Proceso sentado	repre-	Fase donde apor- ta más	Interpretación dentro del protocolo
Media, desviación estándar y rango por eje	Dinámica de aceleración y velocidad angular del segmento.	re-	Movimiento observable, mantenimiento y retorno.	Describen la expresión mecánica del movimiento del brazo, incluyendo desplazamiento, variabilidad, estabilidad y cambios asociados con flexión, extensión, mantenimiento o retorno a reposo.
Magnitud vectorial	Intensidad cinemática global del movimiento.	re-	Ejecución, movimiento observable y retorno a reposo.	Resume la actividad del segmento independientemente del eje principal, aportando una medida compacta de movimiento, estabilidad o retorno hacia la posición inicial.

clasificadores, se aplicó una etapa de reducción de redundancias sobre esta misma:

1. **La eliminación de columnas triviales o constantes:** Donde se descartaron características con la mayoría de sus valores no numéricos (NaN, por sus siglas en inglés, *not a number*) o una varianza nula, ya que no aportaban información.
2. **Un filtrado de redundancia por correlación:** Donde se calculó la correlación de Spearman entre pares de características restantes del paso anterior. Cuando el coeficiente superaba el umbral de 0.95, se eliminaba una de las dos columnas, conservando únicamente un representante del grupo que estaría altamente correlacionado.

Este criterio no implicó descartar observaciones con valores faltantes aislados. La eliminación se aplicó únicamente a características que, durante la construcción de la matriz, no contenían información utilizable para el modelo, ya sea por ser completamente ausentes, no calculables de forma consistente o por presentar va-

rianza nula. Por ejemplo, una característica podía no ser calculable cuando una ventana no contenía muestras válidas de una modalidad o cuando una señal/canal requerido no estaba disponible para una sesión determinada. En estos casos, imputar valores por media, mediana o interpolación habría generado una variable artificial sin soporte suficiente en la señal original. En contraste, los valores faltantes aislados dentro de características conservadas sí fueron tratados mediante imputación por mediana, aplicada después de la eliminación de columnas no informativas y antes de la estandarización y selección final de características. Con esta secuencia de pasos, se transformaron los registros multimodales en vectores de características con una dimensionalidad reducida.

2.3. Entrenamiento, validación y selección del modelo de clasificación

Tras la etapa de procesamiento y extracción de características, el siguiente paso consistió en diseñar, entrenar y optimizar los clasificadores utilizados para detectar la intención motora del usuario. En este trabajo se implementó un esquema de clasificación jerárquica en dos niveles, basado en SVM y validación cruzada estratificada entre sujetos y sesiones, la Figura 2.7 muestra el diagrama general a seguir en esta etapa. El propósito de esta sección es describir el procedimiento utilizado para seleccionar la configuración temporal, los bloques de características y los parámetros de clasificación que posteriormente fueron integrados al sistema en tiempo real del exoesqueleto.

Estructura jerárquica

La clasificación se planteó como un problema jerárquico con dos etapas encaenadas:

- **Nivel 1 (L1): Detección de movimiento vs reposo.**




Figura 2.7. Diagrama de bloques sobre la clasificación jerárquica, mostrando un ejemplo sobre la clasificación de la intención para una flexión.

A partir de las etiquetas de la fase dentro del protocolo y del tipo de movimiento, cada ventana se marcó como reposo (clase 0) o movimiento (clase 1). Específicamente, se etiquetó como movimiento cuando la ventana caía dentro de las fases de ejecución (*execute*) o mantenimiento (*hold*), y presentaba un movimiento etiquetado válido. En este contexto, el término “movimiento” se utilizó como una etiqueta funcional del clasificador L1 y no como la detección de un desplazamiento angular mínimo del brazo. Una ventana se consideró de movimiento cuando correspondía a las fases de ejecución o mantenimiento del protocolo y contenía una clase válida de flexión o extensión. Por tanto, esta etiqueta podía integrar evidencia cortical, neuromuscular y cinemática asociada con el estado activo de la tarea, aun cuando alguna modalidad individual presentara una respuesta débil.

- **Nivel 2 (L2): Discriminación del tipo de movimiento.**

El segundo nivel se entrenó únicamente con las ventanas etiquetadas como

movimiento, con lo que se construyó un vector binario que indicaba flexión o extensión.

Como prueba preliminar de arquitectura, se evaluó un clasificador directo de tres clases, con salidas de reposo, flexión y extensión. No obstante, este enfoque no se mantuvo como configuración final debido a que combinaba en un solo modelo la detección de movimiento y la discriminación del tipo de movimiento. Por ello, se optó por un esquema jerárquico L1–L2, donde cada submodelo resolvió una tarea más específica: primero reposo contra movimiento y después flexión contra extensión. La decisión de cada nivel se obtuvo a partir de las probabilidades calibradas de los clasificadores SVM. Durante las pruebas preliminares se utilizó un umbral de 0.60; posteriormente, se evaluó un valor de 0.50, observándose que el desempeño podía variar según el sujeto. No obstante, para mantener un criterio uniforme y evitar ajustes específicos posteriores a cada participante, en la validación final se fijó un umbral de (0.50) para ambos niveles. Así, L1 clasificó una ventana como movimiento cuando ($P(\text{movimiento}) \geq 0.50$); en caso contrario, la salida se consideró reposo. Cuando L1 detectó movimiento, L2 asignó la dirección a partir de las probabilidades de flexión y extensión utilizando el mismo criterio de decisión. Estos valores corresponden a umbrales sobre probabilidades calibradas del clasificador y no a umbrales directos sobre la amplitud de las señales EEG, sEMG o IMU.

Las matrices de características de todas las sesiones se concatenaron para formar un único conjunto de datos por etapa y por movimiento.

Esquemas de validación

Durante el desarrollo del sistema se emplearon distintos esquemas de validación de acuerdo con el objetivo de cada etapa. El esquema de validación dejando un sujeto fuera (LOSuO, por sus siglas en inglés, *leave-one-subject-out*) se uti-

lizó cuando el propósito fue estimar la capacidad de generalización inter-sujeto, es decir, evaluar el desempeño del modelo ante sujetos no utilizados durante el entrenamiento. En este esquema, todos los registros de un sujeto se reservaron como conjunto de prueba, mientras que el modelo se entrenó con los registros de los sujetos restantes. Este procedimiento se repitió dejando fuera a cada sujeto disponible, de modo que el desempeño obtenido reflejara la capacidad del sistema para transferirse a usuarios no incluidos durante el entrenamiento.

Por otra parte, la validación cruzada estratificada de 5 pliegues (*k-fold*) se empleó en etapas internas donde el objetivo fue comparar configuraciones específicas de manera eficiente dentro del conjunto de desarrollo. En este caso, los datos se dividieron en $k = 5$ particiones, procurando mantener la proporción de clases en cada pliegue. Este esquema fue útil para evaluar configuraciones preliminares con menor costo computacional; sin embargo, no se interpretó como una estimación estricta de generalización hacia sujetos completamente nuevos.

En términos generales, LOSuO se utilizó como criterio principal cuando la etapa metodológica buscaba priorizar la generalización inter-sujeto, mientras que *k-fold* se empleó como herramienta de validación interna para comparar configuraciones durante el desarrollo.

Búsqueda y optimización de hiperparámetros

Las distintas etapas para la obtención del mejor clasificador se dividieron en cuatro diferentes optimizaciones: la selección de parámetros para la extracción de características, el ajuste de los parámetros de la configuración de las SVM, la determinación de la configuración óptima de bloques de señales para la fusión, y, finalmente, la evaluación de pesos diferenciados para cada bloque de características. Estas etapas se visualizan en la Figura 2.8, y son descritas a continuación.




Figura 2.8. Diagrama de flujo de las optimizaciones realizadas durante la extracción de características y el entrenamiento de los clasificadores.

Búsqueda gruesa de parámetros de ventana y CSP

Para la etapa L1 se exploró un conjunto de configuraciones de longitud de ventana y solapamiento definidas como:

- Ancho de la ventana $\in \{0.75, 1.0, 1.25, 1.5\}$ segundos.
- Solapamientos de $\{0.25, 0.5, 0.75\}$ segundos.

generando un total de 12 combinaciones. Para cada ventana de tiempo explorada, la optimización extraía las características para todas las sesiones, aplicaba la eliminación de redundancias, y la evaluación del desempeño bajo el esquema LOSuO. Los resultados de dichas combinaciones se organizaron en orden por F1 macro, seleccionando las configuraciones mejor balanceadas entre desempeño y complejidad.

Para la etapa L2 se realizó una búsqueda análoga sobre los parámetros de sub-bandas CSP considerando:

- Ancho de banda $\in \{6, 8, 10\}$ Hz
- Solapamiento entre subbandas $\in \{0.15, 0.25\}$
- Número de subbandas evaluadas $\in \{4, 6\}$
- Número de componentes CSP retenidos por subbandas $\in \{2\}$

Para cada combinación se extrajeron características de L2, se filtraron las ventanas de flexión y extensión, se aplicó el flujo de reducción de redundancia, y se evaluó el desempeño mediante validación estratificada 5-fold. Los resultados obtenidos se ordenaron de la misma forma que la fase L1.

Optimización fina y búsqueda bayesiana con Optuna

Sobre las regiones más prometedoras identificadas en la búsqueda gruesa, se aplicó una optimización fina de los parámetros de extracción de características, siguiendo un esquema de búsqueda en dos etapas: *coarse-to-fine*. En esta fase se empleó el algoritmo Optuna [51], el cual permitió explorar de forma adaptativa el espacio de hiperparámetros con el objetivo de maximizar el desempeño del modelo bajo el esquema de validación correspondiente.

Es importante señalar que Optuna no constituyó un esquema de validación independiente, sino una herramienta de búsqueda automática de hiperparámetros. El criterio de parada se definió mediante un presupuesto computacional fijo de $n_trials=250$, por lo que la optimización no se ejecutó de manera indefinida. Además, se empleó $n_jobs=6$ para paralelizar la evaluación de ensayos y reducir el tiempo total de búsqueda. No se modificó manualmente el algoritmo de muestreo de Optuna, por lo que la búsqueda se mantuvo dentro de la configuración por defecto de la librería para estudios de un solo objetivo, salvo por el número de ensayos y el grado de paralelización establecidos. En cada ensayo, Optuna propuso una combinación de parámetros; posteriormente, dicha configuración fue evaluada mediante LOSuO o k -fold, según la etapa del desarrollo. La métrica obtenida se utilizó como función objetivo para guiar la búsqueda hacia regiones de mayor rendimiento.

Una vez definidos los mejores parámetros para la extracción de características, se optimizaron los hiperparámetros del clasificador SVM. Los espacios de búsqueda considerados incluyeron:

- Tipo de *kernel*: lineal y RBF (*radial basis function*).
- Parámetro de regularización C , explorado en escala logarítmica desde 10^{-3} hasta 10^3 .

- Parámetro γ para el *kernel* RBF.
- Esquema de pesos por clase: balanceado.

Durante la búsqueda, cada configuración del clasificador fue evaluada mediante LOSuO, con el propósito de priorizar modelos con mayor capacidad de generalización inter-sujeto. De esta forma, la optimización se concentró progresivamente en las regiones del espacio de hiperparámetros asociadas con mejor desempeño.

Tabla 2.7. Relación entre búsqueda de hiperparámetros y esquemas de validación empleados durante el desarrollo del modelo.

Elemento	Función	Uso dentro del desarrollo
Optuna	Búsqueda automática de hiperparámetros.	Propuso combinaciones de parámetros para extracción de características, selección de bloques o configuración del clasificador, según la etapa evaluada.
LOSuO	Validación inter-sujeto.	Se utilizó para evaluar configuraciones cuando el objetivo era priorizar la generalización hacia sujetos no incluidos durante el entrenamiento.
k -fold estratificado ($k = 5$)	Validación interna dentro del conjunto de desarrollo.	Se utilizó para comparar configuraciones específicas con menor costo computacional, manteniendo la proporción de clases en cada pliegue.

Análisis por bloques de características y fusión multimodal

Para cuantificar la contribución relativa de cada modalidad, se organizaron las características en seis bloques dependiendo de su adquisición:

1. EEG
2. sEMG del Biosignalsplux
3. sEMG del MYO
4. IMU acelerómetro
5. IMU giroscopio
6. IMU magnetómetro

El análisis de fusión multimodal se realizó en dos pasos:

1. **Selección de combinaciones entre bloques.** Se evaluaron todas las combinaciones entre bloques utilizando la validación de tipo LOSuO, midiendo la precisión media de clasificación. Conforme a esta métrica, se seleccionó la mejor combinación.
2. **Evaluación preliminar de ponderación por bloque.** Una vez identificada la combinación de modalidades con mejor desempeño, se consideró la posibilidad de asignar pesos escalares distintos a los bloques de características antes de su concatenación. El propósito era explorar si una contribución diferencial de EEG, sEMG e IMU podía mejorar la clasificación respecto a la fusión normalizada sin ponderación. Sin embargo, esta estrategia no se incorporó a la configuración final, debido a que las mejoras observadas no fueron suficientemente consistentes para justificar el aumento de complejidad ni el posible riesgo de sobreajuste. Por tanto, el modelo final utilizó las características seleccionadas de cada modalidad después de su normalización, sin aplicar pesos diferenciados entre bloques.

Por medio de esta optimización se interpretó qué fuentes de información son más críticas para el grado de libertad estudiado.

Métricas de evaluación y criterios de selección de modelos

El desempeño de los clasificadores se evaluó mediante exactitud, precisión, sensibilidad y puntuación F1. Para evitar ambigüedad terminológica, en este trabajo la *exactitud* representa la proporción total de predicciones correctas, mientras que la *precisión* indica qué proporción de las ventanas asignadas a una clase pertenecía efectivamente a dicha clase. La *sensibilidad* cuantifica la proporción de ejemplos reales de una clase que fueron identificados correctamente, y la puntuación F1 corresponde a la media armónica entre precisión y sensibilidad.

Para una clase de interés, estas métricas se definieron como:

$$\text{Exactitud} = \frac{TP + TN}{TP + TN + FP + FN}, \quad (33)$$

$$\text{Precisión} = \frac{TP}{TP + FP}, \quad (34)$$

$$\text{Sensibilidad} = \frac{TP}{TP + FN}, \quad (35)$$

$$F1 = 2 \frac{\text{Precisión} \cdot \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}}, \quad (36)$$

donde TP, TN, FP y FN representan verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos, respectivamente. En problemas multiclase o cuando se resumieron los resultados de ambas clases, las métricas se calcularon primero por clase. El promedio macro asignó la misma importancia a cada clase, mientras que el promedio ponderado consideró su número de observaciones. La exactitud balanceada se calculó como el promedio de la sensibilidad obtenida para cada clase, por lo que fue útil ante diferencias en la cantidad de ventanas disponibles.

En los análisis iniciales de clasificación triclase se utilizó primero la exactitud global y posteriormente la exactitud balanceada, con el propósito de reducir el posible sesgo producido por la mayor cantidad de ventanas de reposo. En las evaluaciones finales del sistema jerárquico se reportaron principalmente precisión y sensibilidad ponderadas, debido a que resumen el desempeño de las clases consideradas respetando su frecuencia dentro de cada bloque experimental.

La latencia se definió de acuerdo con el punto del flujo que se deseaba evaluar. La latencia posterior al cierre de ventana correspondió al tiempo transcurrido desde que estuvieron disponibles todas las muestras de una ventana hasta que la PC produjo la etiqueta de intención. De manera complementaria, la latencia del sistema integrado incluyó las etapas posteriores de comunicación con el cRIO, actualización de la máquina de estados y generación de la referencia de movimiento. Esta distinción evita confundir el tiempo computacional del clasificador con el retardo funcional completo percibido durante la operación HMI-exoesqueleto.

Las métricas anteriores cumplieron funciones diferentes a lo largo del desarrollo. Durante las etapas de optimización se utilizaron principalmente para comparar configuraciones y seleccionar aquella con el mejor compromiso entre desempeño, equilibrio entre clases y costo computacional, sin imponer necesariamente un valor mínimo absoluto para cada búsqueda. En cambio, para la validación experimental final se adoptaron como referencias los valores definidos en la hipótesis: precisión ponderada y sensibilidad ponderada iguales o superiores a 0.80, así como una latencia media posterior al cierre de ventana menor a 100 ms. La Tabla 2.8 resume el uso de las métricas y los criterios considerados en cada etapa.

De esta forma, las métricas utilizadas durante la optimización permitieron seleccionar configuraciones de manera comparativa, mientras que los valores de 0.80 para precisión y sensibilidad ponderadas y de 100 ms para latencia media posterior al cierre de ventana constituyeron los criterios de referencia para eva-

Tabla 2.8. Métricas y criterios utilizados en las distintas etapas de desarrollo y validación del sistema.

Etapa	Métricas principales	Criterio de selección o valor esperado
Optimización de ventana para L1	Exactitud, F1 macro y exactitud balanceada.	Selección de la configuración con mejor equilibrio global entre clases y desempeño medio. No se impuso un umbral mínimo absoluto; el criterio fue comparativo entre las configuraciones evaluadas.
Optimización del banco CSP para L2	Función objetivo, exactitud, F1 y exactitud balanceada.	Selección de la configuración que maximizó la función objetivo y mantuvo un desempeño balanceado entre flexión y extensión, considerando también el costo de procesamiento por pliegue.
Selección de hiperparámetros SVM	Métrica media obtenida bajo LOSuO o validación estratificada, según la etapa.	Selección de la combinación de <i>kernel</i> y parámetros con mayor desempeño de validación, priorizando la generalización intersujeto cuando se utilizó LOSuO.
Comparación de modalidades	Precisión y sensibilidad ponderadas.	Identificación de la combinación de señales con mejor desempeño global respecto a las modalidades aisladas, sin exigir una mejora mínima prefijada.
Simulación <i>offline</i>	Precisión, sensibilidad, F1, exactitud y matriz de confusión.	Verificar la correcta operación del procesamiento, la clasificación jerárquica y la separación entre reposo, flexión y extensión sobre registros pregrabados. Los resultados se utilizaron como verificación descriptiva, no como criterio final de aceptación.
Simulación <i>online</i> sin exoesqueleto	Precisión, sensibilidad, F1, matriz de confusión y latencia posterior al cierre de ventana.	Evaluar la estabilidad de decisiones consecutivas y confirmar que el flujo pudiera operar con señales adquiridas en tiempo real. Como referencia temporal se consideró deseable una latencia media menor a 100 ms.
Simulación con exoesqueleto	Latencia del sistema integrado, estabilidad de estados y respuesta de la referencia articular.	Verificar la comunicación PC–cRIO, la máquina de estados y la generación segura de movimiento. Esta etapa tuvo un propósito principalmente funcional.
Validación experimental final	Precisión ponderada, sensibilidad ponderada y latencia media posterior al cierre de ventana.	De acuerdo con la hipótesis, se esperaron valores de precisión y sensibilidad iguales o superiores a 0.80, y una latencia media posterior al cierre de ventana menor a 100 ms.

luar el cumplimiento de la hipótesis en la etapa experimental final. Las métricas temporales asociadas al controlador y al sistema integrado se analizaron adicionalmente como indicadores funcionales, pero no se confundieron con la latencia computacional posterior al cierre de ventana.

Con fines de reproducibilidad, los procedimientos de procesamiento, optimización, clasificación y análisis estadístico se implementaron en entornos de Python con versiones controladas de las bibliotecas utilizadas. Los clasificadores SVM, la validación cruzada, la calibración probabilística, ICA y los procedimientos de preprocesamiento se implementaron mediante *scikit-learn*; la búsqueda de hiperparámetros se realizó con Optuna; y los modelos lineales mixtos se ajustaron mediante *MixedLM* de *statsmodels*. Las versiones específicas de los entornos y bibliotecas, junto con las clases y configuraciones principales empleadas, se resumen en el Apéndice B.

2.4. Plataforma experimental

Para implementar y validar el sistema de detección de intenciones y control de asistencia para la extremidad superior derecha, se utilizó un sistema robótico de tipo exoesqueleto de tres grados de libertad, desarrollado en el Laboratorio de Robótica de la Facultad de Ciencias de la UASLP. Este exoesqueleto está diseñado para rehabilitación de hombro y codo, y permite reproducir movimientos del brazo en un espacio tridimensional [52].

Con el fin de distinguir entre la infraestructura previamente disponible en el laboratorio y los elementos desarrollados, implementados o modificados durante esta tesis, la Tabla 2.9 resume el origen y la función de los principales componentes de la plataforma experimental. Esta distinción permite identificar con mayor claridad la aportación específica del presente trabajo dentro de una plataforma robótica y de control desarrollada previamente por el grupo de investigación.

Tabla 2.9. Distinción entre elementos heredados de la plataforma del laboratorio y aportaciones implementadas durante esta tesis.

Elemento	Base heredada o previamente disponible	Implementación, adaptación o modificación realizada en esta tesis
Exoesqueleto de miembro superior	Plataforma mecánica desarrollada previamente por el grupo de investigación, incluyendo estructura, articulaciones y sistema de actuación.	Uso de la plataforma como sistema robótico de validación para evaluar la detección de intención motora y su integración con el flujo HMI-exoesqueleto.
Controlador de interacción humano-robot	Estrategia de control basada en impedancia con acciones acotadas, previamente desarrollada y reportada por el grupo de investigación [53].	Implementación experimental del controlador en el entorno embebido utilizado para esta tesis, así como su integración con los comandos discretos provenientes del sistema de detección de intención.
Sistema embebido cRIO-9067 y módulos NI	<i>Hardware</i> de control disponible en el laboratorio, incluyendo controlador embebido y módulos asociados para la interfaz con el exoesqueleto.	Configuración e implementación en LabVIEW Real-Time para recibir comandos de intención, ejecutar lógica de estados, generar referencias articulares y comunicarse con el sistema de procesamiento externo.

Continúa en la siguiente página

Elemento	Base heredada o previamente disponible	Implementación, adaptación o modificación realizada en esta tesis
Comunicación PC–cRIO	Infraestructura de red y capacidad de comunicación entre la computadora de procesamiento y el controlador embebido.	Implementación de comunicación UDP para transferir la intención detectada desde Python hacia el cRIO, incluyendo registro de tiempos y variables relevantes para análisis de latencia.
Sistema de adquisición multimodal	Disponibilidad de dispositivos EEG, sEMG e IMU en el laboratorio.	Diseño del protocolo experimental, sincronización de señales, organización de sesiones, estructura de eventos, adquisición multimodal y preparación de archivos para procesamiento.
Procesamiento y clasificación en Python	Herramientas de programación y librerías de análisis disponibles.	Desarrollo de <i>scripts</i> para limpieza, segmentación, extracción de características EEG–sEMG–IMU, reducción de redundancias, entrenamiento, validación fuera de línea y simulación en línea.

Continúa en la siguiente página

Elemento	Base heredada o previamente disponible	Implementación, adaptación o modificación realizada en esta tesis
Arquitectura HMI jerárquica	Conceptos generales de detección de intención y clasificación supervisada reportados en la literatura.	Diseño e implementación del esquema jerárquico L1–L2, donde L1 discrimina reposo/movimiento y L2 clasifica flexión/extensión, así como su integración con la máquina de estados del exoesqueleto.
Validación experimental	Plataforma robótica y entorno de pruebas disponibles en el laboratorio.	Diseño y ejecución de pruebas progresivas, simulaciones, validación en tiempo real y análisis de precisión, sensibilidad y latencia del sistema integrado.

A partir de esta base, el sistema mecánico se complementó con una plataforma de control en tiempo real basada en un sistema embebido cRIO–9067 (National Instruments), módulos de control de movimiento para el accionamiento de los motores, módulos para adquisición de variables de estado y módulos de salida analógica para el envío de comandos hacia los actuadores. Esta integración permitió utilizar la infraestructura robótica disponible como banco de pruebas para validar la operación del sistema HMI–exoesqueleto desarrollado en esta tesis.

En conjunto, la plataforma permitió cerrar el flujo experimental desde la detección de intención hasta la generación de movimiento asistido. Las señales de EEG, sEMG e IMU fueron adquiridas y procesadas en la computadora de la HMI; posteriormente, las decisiones de intención se enviaron al cRIO mediante comunicación UDP, donde se integraron con la máquina de estados, la generación de

referencias articulares y el controlador del exoesqueleto. Una descripción visual de esta arquitectura y su conexión con el sistema HMI se muestra en la Figura 2.9.

Con esta organización, la plataforma experimental no solo funcionó como un banco de pruebas mecánico, sino como el entorno de validación integrada del sistema HMI-exoesqueleto en tiempo real. A continuación, se describen los principales elementos que conformaron dicha plataforma, iniciando con el sistema robótico tipo exoesqueleto.

2.4.1. Sistema robótico tipo exoesqueleto

El sistema robótico utilizado en este proyecto es un exoesqueleto de tres grados de libertad para miembro superior derecho. Con dos grados de libertad activos en el hombro y uno en el codo, siguiendo la configuración propuesta y utilizada en trabajos previos del grupo de investigación [52, 54], este sistema robótico se muestra en la Figura 2.10.

En particular, el robot permite realizar los siguientes movimientos:

- Flexión/extensión de codo.
- Flexión/extensión de hombro.
- Rotación medial/lateral del hombro.

Los pares objetivo para cada articulación se definieron a partir de la literatura sobre espasticidad después de un evento vascular cerebral, donde se reporta que un par cercano a 20 Nm es suficiente para vencer la resistencia del hombro y codo durante movimientos de flexión y extensión [52]. Por lo que se conservaron los pares propuestos, manteniendo como requisitos del diseño y puesta a prueba 30 Nm para flexión y extensión de hombro, 10 Nm para rotación medial y lateral de hombro, y 5 Nm para flexión y extensión de codo. Estos valores fueron utilizados para obtener la configuración descrita en la subsección siguiente.




Figura 2.9. Diagrama de bloques sobre la plataforma experimental y su conexión con el sistema HMI.




Figura 2.10. Plataforma experimental de tipo exoesqueleto utilizada.

Actuadores, controlador embebido y módulos de entrada/salida

Cada grado de libertad activo fue accionado mediante un motor de corriente continua de la familia Dunker motoren GR, acoplado a una caja de engranajes planetarios (PLG, por sus siglas en inglés, *Planetary GearBox*) y comandado por un controlador de potencia BGE dedicado. Los motores operan a 24 V, incluyen un encoder incremental integrado de 500 ppr y están diseñados para trabajar en modo par, esto mediante sus *drivers*, de forma que el par aplicado es aproximadamente proporcional al voltaje recibido en la entrada analógica del controlador.

La configuración final por articulación es la siguiente:

- **Articulación de codo (flexión/extensión):** Se utiliza un motor Dunker motoren GR 56×30, una caja de engranajes PLG 52 y un *driver* de potencia BGE 6005A.
- **Articulación de hombro (flexión/extensión):** Se emplea un motor Dunker motoren GR 80×80, una caja de engranajes PLG 75LN y un *driver* de potencia BGE 6010 A.

- **Articulación de hombro (rotación medial/lateral):** Aquí se utilizó un motor Dunkermotoren GR 63×55, una caja de engranajes PLG 52, y un *driver* de potencia BGE 6005 A.

La interfaz entre el exoesqueleto y el controlador en tiempo real se realizó mediante un cRIO 9067 (National Instruments) equipado con los siguientes módulos de la serie C:

- **Un módulo NI 9264 (salida analógica):** el cual proporciona hasta 8 salidas analógicas $\pm 10V$ de 16 bits. Para este proyecto, se utilizó un canal por articulación; el voltaje de cada canal se conectó a la entrada analógica *Ain0* del *driver* BGE correspondiente, y de esta forma poder utilizar la configuración de par/velocidad del motor.
- **Tres módulos NI 9514 (control de servomotor):** Cada módulo controla un eje de los 3 grados de libertad; reciben directamente las señales de los codificadores incrementales de los motores y permiten la lectura de variables de estado como posición, velocidad, estado del eje, desde el entorno de labVIEW Real-Time [55].
- **Un módulo CANbus:** para la lectura de los mensajes de error, la selección de configuración del motor y el monitoreo de correcto funcionamiento de cada actuador.

En relación con la implementación previa de la plataforma, basada en una tarjeta analógica-digital multifunción Sensoray 826 programada en C++ y operada con un periodo de muestreo de 1 ms [52], la migración al cRIO-9067 permitió mantener la misma filosofía de accionamiento del exoesqueleto en modo par/velocidad mediante señales analógicas hacia los *drivers*, pero incorporando una arquitectura embebida más adecuada para la integración con la HMI. En particular, el uso de

LabVIEW Real-Time y módulos dedicados de la serie C facilitó la lectura de variables de estado de los ejes, la generación de salidas analógicas, la comunicación UDP con la PC de procesamiento y el registro sincronizado de eventos y latencias. De esta forma, la plataforma no solo conserva la capacidad de control en tiempo real del sistema original, sino que añade una capa de integración, supervisión y trazabilidad temporal necesaria para evaluar el funcionamiento cerrado del sistema HMI-exoesqueleto.

2.4.2. Arquitectura general del sistema HMI-exoesqueleto

La Figura 2.9 presenta la arquitectura global del sistema HMI. En general, la integración se organizó en cuatro partes:

1. **Capa de usuario y sensado.** De inicio, el usuario portó los sensores de EEG, sEMG e IMU. Estas señales reflejan la actividad cortical, muscular y cinemática asociada con los movimientos y a la imaginación motora del miembro superior derecho.
2. **Capa de adquisición y procesamiento HMI.** En una computadora de procesamiento se ejecutaron los módulos en Python encargados de adquirir las señales en tiempo real, aplicar el preprocesamiento y el ventaneo, extraer las características multimodales y evaluar los clasificadores jerárquicos L1-L2 previamente entrenados. A partir de estas salidas, la capa de HMI generó comandos tipo *REST*, *FLEX* o *EXT*, (indicadores de reposo, flexión o extensión, respectivamente) acompañados de información temporal y de confianza.
3. **Capa de control del exoesqueleto.** El comando de intención se envió desde la PC al sistema embebido cRIO-9067 mediante un canal de comunicación UDP. En el cRIO se ejecutó el controlador de las articulaciones, un

controlador de impedancia adaptable con acciones acotadas, implementado en LabVIEW Real-Time y apoyado en los módulos NI 9514 y NI 9264; además de la lógica que traduce el comando *REST/FLEX/EXT* en referencia de posición para cada motor.

4. Tanto la PC como el cRIO registraron continuamente variables relevantes. En la PC se almacenaron las decisiones de los clasificadores, las probabilidades, las etiquetas de eventos y las marcas de tiempo. En el cRIO se registraron las posiciones articulares, los torques de referencia, los estados de los ejes y las latencias de activación. Estos registros permitieron analizar posteriormente el desempeño del sistema integrado, estimar las latencias extremo a extremo y ajustar parámetros de control y de clasificación.

Comunicación y sincronización entre la HMI y el cRIO

La integración entre la interfaz humano-máquina implementada en la PC de procesamiento, y el sistema embebido del exoesqueleto se realizó mediante un canal de comunicación en red basado en UDP. El objetivo de esta capa fue transmitir, de forma rápida y ligera, los comandos de intención generados por el clasificador, y al mismo tiempo registrar información suficiente para analizar latencias y desempeño del sistema integrado.

En el cRIO, en LabVIEW se implementó un bucle dedicado a la recepción UDP, el cual escuchaba continuamente el puerto configurado, decodificaba la cadena recibida, actualizaba las variables de intención y registraba el tiempo local de recepción.

Sincronización temporal entre PC y controlador

Para poder analizar las latencias extremo a extremo y asegurar coherencia temporal entre los registros de la PC y el cRIO, se definió una referencia de

tiempo común al inicio de cada sesión. Al comenzar la sesión, el código encargado de adquirir las señales generaba un tiempo de referencia y enviaba un mensaje al cRIO; el cRIO registraba el instante local en que recibía este mensaje y lo asociaba con el valor inicial recibido. A partir de aquí, todos los eventos y comandos se almacenan en ambos sistemas con tiempos relativos a ese origen común.

2.4.3. Máquina de estados y estrategias de seguridad

Para traducir la salida del clasificador y poder enviarla al controlador del exoesqueleto se implementó en el cRIO una máquina de estados. Esta recibía, en cada ventana de clasificación, la intención estimada y decidía si el robot debía permanecer en reposo, asistir una flexión, asistir una extensión o ejecutar un frenado antes de regresar a reposo.

1. Señales de entrada.

En cada ventana de clasificación, la PC enviaba un conjunto de datos, entre los cuales se incluía un entero que representaba “la intención cruda”, dicho valor podía tomar los siguientes significados:

- +1 $\rightarrow$ intención de flexión
- 0 $\rightarrow$ reposo.
- -1 $\rightarrow$ intención de extensión.

En el cRIO, esta señal pasaba por un filtrado temporal que eliminaba cambios muy breves e inconsistentes, produciendo una señal limpia, es decir, “la intención filtrada” (*intent_{filtered}*). La máquina de estados se alimentaba únicamente de la intención filtrada, de modo que las decisiones aisladas o espacios temporales perdidos no provocaran cambios abruptos de estado.

2. Estados.

Se utilizaron cuatro estados lógicos:

- **Inactivo:** El sistema está en reposo, sin asistencia.
- **Assist_{Flex}:** Se asiste un movimiento de flexión.
- **Assist_{Ext}:** Se asiste un movimiento de extensión.
- **Brake:** Freno corto antes de regresar a reposo.

Además de los estados, el controlador utilizó dos variables de referencia:

- **q_{goal} :** Es el objetivo discreto de posición en grados ($-20^\circ, 0^\circ, +45^\circ$). En esta implementación, 0° corresponde a la posición neutra o anatómica inicial del exoesqueleto; -20° se asignó al objetivo de extensión y $+45^\circ$ al objetivo de flexión.
- **q_{ref} :** Es la referencia suave que sigue una trayectoria en una curva S hacia q_{goal} .

3. **Reglas de transición.** Para regular la estabilidad temporal de la máquina de estados se definieron varios parámetros expresados en milisegundos.

- **$enter_{ms}$:** Tiempo mínimo que la intención filtrada debe permanecer estable antes de entrar a un estado de movimiento.
- **$flip_{ms}$:** Tiempo mínimo requerido para aceptar una transición directa entre intenciones opuestas, como flexión a extensión.
- **$hold_{ms}$:** Tiempo durante el cual se mantiene el último estado válido ante pérdidas breves de intención.
- **$brake_{ms}$:** Duración del estado de frenado empleado para suavizar el retorno hacia reposo.
- **$watchdog_{ms}$:** Tiempo máximo permitido sin recibir paquetes válidos antes de forzar un estado seguro.

La lógica de la máquina de estados se resume en las siguientes reglas:

a) **Regla 1: De inactivo a asistencia.**

- Si $intent_{filtered} = +1$ se mantenía al menos durante $enter_{ms}$, el estado cambiaba de *Inactivo* a *Assist_{Flex}* y se fijaba $q_{goal} = +45^\circ$.
- Si $intent_{filtered} = -1$ se mantenía al menos $enter_{ms}$, el estado cambiaba de *Inactivo* a *Assist_{Ext}* y se fijaba $q_{goal} = -20^\circ$.

Es decir, la intención recibida debía ser estable durante un intervalo mínimo de tiempo para iniciar la asistencia.

b) **Regla 2: Mantenerse asistiendo/Cambiar de dirección.**

- Si el sistema estaba en *Assist_{Flex}* y aparecía puntualmente un $intent_{filtered} = -1$ que durara menos de $flip_{ms}$, se consideraba ruido y el estado no cambiaba.
- Si $intent_{filtered} = -1$ se mantenía durante al menos $flip_{ms}$, el estado cambiaba de *Assist_{Flex}* a *Assist_{Ext}* y se actualizaba $q_{goal} = -20^\circ$.
- De forma análoga de *Assist_{Ext}* a *Assist_{Flex}* y $q_{goal} = +45^\circ$.

Con esto, el usuario podía invertir la dirección de ayuda si sostenía la intención contraria el tiempo suficiente, pero pequeñas indecisiones o el reposo no activaban esta regla.

c) **Regla 3: Salir de asistencia.** Si $intent_{filtered} = 0$ y se acumulaba durante un tiempo $hold_{ms}$, es decir, el usuario dejaba de mostrar intención de movimiento, el estado pasaba de *Assist_{Flex}* o *Assist_{Ext}* a *Brake*. Esta regla representaba “soltar” la intención, lo que iniciaba un frenado controlado.

d) **Regla 4: Freno corto (*Brake*).** Durante el estado de *Brake*, se fijó $q_{goal} = 0^\circ$, así mismo, si transcurría un tiempo $brake_{ms}$, el estado pasaba de *Brake* a *Inactivo*. De esta manera, ante la pérdida de la intención, el robot aplicaba un freno suave antes de volver a reposo.

- e) **Regla 5: *Watchdog* de seguridad.** Si no llegaba ningún paquete de Python durante un intervalo $watchdog_{ms}$, el sistema forzaba $intent_{filtered} = 0$. A partir de aquí, la lógica normal llevaba al sistema a estado de *Brake* y luego a *Inactivo*, de modo que una pérdida de comunicación regresaba al exoesqueleto a una postura segura.

Con estas reglas la máquina de estados transformaba una orden posiblemente ruidosa del clasificador en una secuencia de estados bien definida, evitando oscilaciones rápidas e incrementando la seguridad para el usuario.

4. **Generación de referencias de posición.** Una vez que la máquina de estados definía el objetivo discreto q_{goal} , el cRIO generaba una trayectoria suave $q_{ref}(t)$ que seguía ese objetivo sin cambios bruscos. Esto se implementó en LabVIEW mediante un generador de trayectoria en curva S (sigmoidea), implementada como una aproximación por medio de un polinomio de grado 5.

En cada iteración del lazo de control se comparaba el nuevo q_{goal} con el valor de q_{goal} del ciclo anterior. Si había un cambio en este parámetro, se consideraba que había un nuevo movimiento a realizar. Así, se calculaba la distancia angular absoluta restando el nuevo q_{goal} con q_{ref} y se inicializaban las variables internas del generador de trayectorias, $q_{start} = q_{ref}$ en ese instante y se reiniciaba el parámetro de fase $s = 0$.

5. **Curva en S.** Durante el movimiento, el generador de trayectoria actualizaba una variable adimensional $s \in [0, 1]$ que representaba el avance relativo de la trayectoria: $s_k + 1 = \min(1, s_k + \Delta t/T)$, donde Δt es el periodo de muestreo en ms, y T es el tiempo total de movimiento. Con este parámetro se evaluaba

la clásica curva S de quinto orden:

$$u(s) = 10s^3 - 15s^4 + 6s^5 \quad (37)$$

y la referencia se actualizaba como:

$$q_{ref} = q_{start} + u(s_k)(q_{goal} - q_{start}) \quad (38)$$

- Cuando $s = 0$, $u(0) = 0$ y $q_{ref} = q_{start}$.
- Cuando $s = 1$, $u(1) = 1$ y $q_{ref} \approx q_{goal}$.
- La forma en S garantizaba una aceleración inicial y final nulas, y una velocidad máxima en el centro del movimiento.

Así, en estados de *Assist_{Flex}* o *Assist_{Ext}*, q_{goal} tomaba los valores $+45^\circ$ o -20° , respectivamente, y se disparaba una nueva curva S desde la posición actual.

El controlador de impedancia descrito en subsecciones anteriores utiliza esta q_{ref} como referencia de posición articular deseada, equivalente a q_D en la formulación de control. En cada ciclo de control, esta referencia se comparaba con la posición articular actual del exoesqueleto, denotada como q y obtenida a partir de la lectura de los encoders, para calcular el error de seguimiento $q_{ref} - q$ y generar el torque correspondiente. De este modo, la combinación del clasificador, la máquina de estados, el generador de curva S y el controlador de impedancia transformaban las decisiones discretas de intención en movimientos continuos, suaves y acotados del exoesqueleto. Los valores dados a los parámetros empleados durante la experimentación se presentan en el Apéndice D.

Controlador del exoesqueleto

El exoesqueleto de tres grados de libertad se controló mediante un esquema de control de impedancia con acciones acotadas, basado en la formulación propuesta para interacción humano-robot en exoesqueletos [53]. La elección de este enfoque responde a la necesidad de transformar las referencias de movimiento generadas por la HMI en acciones de control seguras, evitando que los torques aplicados a los actuadores excedan los límites físicos del sistema. A diferencia de un controlador puramente cinemático, el control de impedancia permite regular la relación dinámica entre movimiento, error de seguimiento e interacción con el usuario [52, 53, 56].

De forma general, la dinámica articular del exoesqueleto puede escribirse como:

$$H(q)\ddot{q} + C(q, \dot{q})\dot{q} + F\dot{q} + g(q) = \tau - \tau_E, \quad (39)$$

donde q , $\dot{q}$ y $\ddot{q}$ representan la posición, velocidad y aceleración articular del robot, respectivamente; $H(q)$ es la matriz de inercia, $C(q, \dot{q})$ agrupa los términos centrífugos y de Coriolis, F representa la fricción viscosa, $g(q)$ corresponde al vector de torques gravitacionales, τ es el torque de control aplicado por los actuadores y τ_E representa el torque de interacción ejercido por el usuario sobre el robot.

En un esquema de impedancia, el movimiento del robot se ajusta en función de la interacción con el usuario. Esta relación puede expresarse como:

$$q - q_D = [H_E s^2 + D_E s + K_E]^{-1} \tau_E, \quad (40)$$

donde q_D es la trayectoria deseada en ausencia de interacción, y H_E , D_E y K_E son matrices positivas definidas asociadas con la inercia, amortiguamiento y rigidez

deseadas durante la interacción. En este contexto, el término

$$[H_E s^2 + D_E s + K_E]^{-1} \tau_E$$

puede interpretarse como el ajuste de movimiento producido por la interacción humano-robot.

A partir de esta relación se define el error de impedancia $\bar{\xi}$ como:

$$\bar{\xi} = \bar{q} - q_E, \quad (41)$$

con:

$$\bar{q} = q - q_D, \quad q_E = [H_E s^2 + D_E s + K_E]^{-1} \tau_E, \quad (42)$$

donde $\bar{q}$ corresponde al error de seguimiento en espacio articular y q_E representa el ajuste de trayectoria debido a la interacción. Bajo esta formulación, el objetivo del controlador es conducir el error de impedancia hacia cero, manteniendo al mismo tiempo los torques de control dentro de los límites de los actuadores:

$$|\tau_i| < T_i, \quad \lim_{t \rightarrow \infty} \bar{\xi} = 0. \quad (43)$$

donde τ_i representa el torque de control aplicado en la articulación i y T_i corresponde al límite máximo de torque permitido para dicha articulación. Esta condición resume que el controlador busca reducir el error de interacción sin exceder las capacidades físicas de los actuadores.

La ley de control empleada se basa en acciones proporcional y derivativa acotadas, compensación dinámica y compensación de interacción. De forma general, puede expresarse como:

$$\tau = -s_P(K_P \bar{\xi}) - s_D(K_D \dot{\bar{\xi}}) + Y(q, \dot{q}_H, \ddot{q}_H) \hat{\theta} + \tau_E^{sat}, \quad (44)$$

donde K_P y K_D son las matrices de ganancia proporcional y derivativa; $s_P(\cdot)$ y $s_D(\cdot)$ son funciones de saturación que acotan las acciones proporcional y derivativa; $Y(q, \dot{q}_H, \ddot{q}_H) \hat{\theta}$ representa la compensación dinámica con parámetros estimados; y τ_E^{sat} corresponde a la contribución de interacción acotada. Esta formulación permite que la acción de control permanezca limitada, aun cuando el error de seguimiento o su derivada aumenten, lo cual es fundamental para la operación segura del exoesqueleto.

Para mostrar explícitamente el papel de los parámetros de configuración, las acciones saturadas pueden escribirse componente a componente como:

$$s_{P_i}(K_{P_i} \bar{\xi}_i) = \begin{cases} K_{P_i} \bar{\xi}_i, & \text{si } |K_{P_i} \bar{\xi}_i| \leq L_{P_i}, \\ \rho_{P_i}(\bar{\xi}_i), & \text{si } |K_{P_i} \bar{\xi}_i| > L_{P_i}, \end{cases} \quad (45)$$

$$s_{D_i}(K_{D_i} \dot{\bar{\xi}}_i) = M_{D_i} \text{sat} \left(\frac{K_{D_i} \dot{\bar{\xi}}_i}{M_{D_i}} \right), \quad (46)$$

donde M_{P_i} y M_{D_i} representan los límites superiores de las acciones proporcional y derivativa saturadas para la articulación i , respectivamente, y L_{P_i} define la región lineal de la acción proporcional. En la práctica, esto implica que para errores pequeños el controlador se comporta de forma similar a un control proporcional-derivativo convencional, mientras que para errores mayores la acción se suaviza y se mantiene dentro de límites preestablecidos.

La función no lineal ρ_{P_i} se define como:

$$\rho_{P_i}(\bar{\xi}_i) = L_{P_i} \text{sign}(K_{P_i} \bar{\xi}_i) + (M_{P_i} - L_{P_i}) \tanh \left(\frac{K_{P_i} \bar{\xi}_i - L_{P_i} \text{sign}(K_{P_i} \bar{\xi}_i)}{M_{P_i} - L_{P_i}} \right). \quad (47)$$

Esta función permite una transición continua entre la región lineal y la región saturada, evitando cambios abruptos en el torque aplicado.

Además de las cotas asociadas a las acciones proporcional y derivativa, la formulación considera una cota para el término de interacción. Para cada articulación i , las cotas del controlador deben satisfacer la condición:

$$M_{P_i} + M_{D_i} + B_{D_i}^{\hat{\theta}^A} + M_{E_i} < T_i, \quad (48)$$

donde M_{P_i} , M_{D_i} y M_{E_i} corresponden a las cotas asociadas a las contribuciones proporcional, derivativa y de interacción, respectivamente; $B_{D_i}^{\hat{\theta}^A}$ representa una cota superior asociada al término de compensación dinámica estimada; y T_i es el límite máximo de torque permitido para la articulación i . Esta desigualdad establece que la suma de las contribuciones acotadas del controlador debe permanecer por debajo de la capacidad de torque del actuador. De esta manera, M_E no actúa como una ganancia del controlador, sino como el límite máximo permitido para la contribución del término de interacción dentro de la ley de control.

La Ecuación 44 resume la ley de control general. Además de las acciones saturadas proporcional y derivativa descritas en las ecuaciones anteriores, la formulación incorpora una actualización adaptativa de los parámetros estimados de la dinámica del robot. Esta actualización se expresa mediante una variable auxiliar ϕ , cuya dinámica puede escribirse de forma general como:

$$\dot{\phi} = -\Gamma Y^T(q, \dot{q}_H, \ddot{q}_H) [\bar{\xi} + \epsilon s_P(K_P \bar{\xi})], \quad (49)$$

$$\hat{\theta} = s_A(\phi), \quad (50)$$

donde Γ es la matriz de ganancias adaptativas, $Y(q, \dot{q}_H, \ddot{q}_H)$ es la matriz regresora dinámica, ϕ es una variable auxiliar de adaptación, $s_A(\cdot)$ es una función de sa-

turación aplicada a los parámetros estimados, y $s_P(K_P \bar{\xi})$ corresponde a la acción proporcional acotada. donde Γ es la matriz de ganancias adaptativas, $Y(q, \dot{q}_H, \ddot{q}_H)$ es la matriz regresora dinámica, ϕ es una variable auxiliar de adaptación, $s_A(\cdot)$ es una función de saturación aplicada a los parámetros estimados, y $s_P(K_P \bar{\xi})$ corresponde a la acción proporcional acotada. En esta expresión, ϵ pondera la contribución de la acción proporcional saturada dentro de la ley adaptativa; por tanto, no debe interpretarse como una ganancia proporcional directa, sino como un parámetro auxiliar que regula la actualización de los parámetros estimados.

Los valores utilizados para las cotas de saturación, las ganancias adaptativas y los parámetros auxiliares del controlador se resumen en el Apéndice C. En particular, la Tabla C.1 presenta los valores generales de saturación y ganancia adaptativa utilizados en la configuración del controlador, mientras que la Tabla C.2 reporta, por motor, las ganancias K_P y K_D , los límites de saturación M_P , M_D y M_E , así como el parámetro auxiliar ϵ . Estas expresiones se incluyen para identificar el papel de los parámetros utilizados en la implementación, no para reproducir la derivación completa del controlador, la cual se encuentra desarrollada en la formulación original del método [53].

En la implementación desarrollada, la salida de la máquina de estados no se aplicó directamente como referencia instantánea del controlador. Primero, la intención estable se transformó en un objetivo discreto de posición, denotado como q_{goal} . Posteriormente, se generó una trayectoria suave $q_{\text{ref}}(t)$ mediante un perfil polinomial tipo curva S. Esta trayectoria suavizada fue utilizada como la posición deseada del controlador, por lo que en la formula de control se considera que $q_D(t) \equiv q_{\text{ref}}(t)$. De esta manera, q_{goal} representa el valor final deseado, mientras que $q_D(t)$ corresponde a la referencia temporal continua que debe seguir el exoesqueleto.

El lazo de control se ejecutó sobre el cRIO-9067 mediante LabVIEW Real-

Time, con una latencia de operación media de ≈ 23 ms. Esta implementación permitió cerrar en tiempo real el lazo de control asociado a la generación de torque, utilizando la referencia articular generada por la HMI y las mediciones de posición del exoesqueleto para calcular las acciones de control enviadas a los actuadores.

2.4.4. Validación progresiva del sistema HMI–exoesqueleto

Como se anticipó en la Tabla 2.2, el protocolo de adquisición multimodal constituyó la base para una estrategia progresiva de validación. Esta estrategia permitió avanzar desde registros previamente adquiridos hasta la operación completa del sistema HMI–exoesqueleto en tiempo real, incrementando gradualmente el grado de acoplamiento entre señales, clasificador, comunicación con el cRIO, máquina de estados, controlador y movimiento del exoesqueleto.

Bajo este enfoque, las simulaciones se consideraron como etapas intermedias entre la adquisición inicial de señales y la validación experimental final. Cada etapa permitió verificar un componente específico del flujo HMI–exoesqueleto y finalmente la operación completa en tiempo real con usuarios instrumentados.

Simulaciones

Antes de integrar la interfaz para la HMI al exoesqueleto y realizar las pruebas finales, se diseñó una etapa intermedia de simulaciones que permitió verificar por separado cada componente del sistema, es decir, la comunicación entre dispositivos, los filtros en tiempo real, la máquina de estados y la generación de trayectorias. De forma que, en esta etapa se depuraba la lógica del flujo de operación, así como se comprobaba que el sistema se comportara de forma estable y reproducible bajo diferentes escenarios.

Para este propósito, se definieron tres modos principales de simulación, los

cuales se describen a continuación:

1. Pruebas *offline* con base de datos:

En este primer escenario se utilizaron exclusivamente señales previamente adquiridas y almacenadas. Estos registros se reproducían en la PC de procesamiento y alimentaba al sistema como si estuvieran llegando esas señales en tiempo real, donde se aplicaban *online* las mismas etapas de procesamiento, ventaneo, extracción de características, clasificación jerárquica L1-L2, filtrado temporal de la intención y máquina de estados.

En esta configuración no había una persona conectada a los sistemas de adquisición, ni el exoesqueleto activo; la intención estimada se visualizaba en pantalla, así como la curva de posición que debería seguir el exoesqueleto de forma controlada.

Además, estos bloques de simulación se evaluaron utilizando tres bases de datos pregrabadas, las cuales representaban distintos niveles de generalización del algoritmo:

- Una sesión incluida en el entrenamiento.
- Una sesión de un sujeto conocido por el clasificador pero no utilizada durante el entrenamiento.
- Una sesión de un sujeto desconocido para el modelo.

Además, se utilizó la sesión del sujeto conocido no incluida durante el entrenamiento, descrita en el segundo caso anterior, para probar distintas configuraciones de modalidades de entrada. Para ello, se consideraron todas las combinaciones posibles de los tres bloques de señales EEG, sEMG e IMU. Estas variantes permitieron analizar tanto la capacidad de generalización del sistema ante una sesión no vista de un sujeto conocido, como la contribución relativa de cada modalidad sensorial.

2. Pruebas *online* con una persona:

En segunda instancia se dio el paso a utilizar señales en vivo, manteniendo todavía desconectado el exoesqueleto del sistema. Aquí, la persona portaba los sensores de EEG, sEMG e IMU, y la PC realizaba la adquisición en tiempo real, el procesamiento y la clasificación jerárquica. La salida del clasificador se seguía mostrando en pantalla, así como la referencia de posición. Esta prueba se realizó con el apoyo de un sujeto presente en la etapa de adquisición, quien regresó al laboratorio para adquirir señales adicionales.

3. Simulación del control en lazo cerrado con base de datos:

En el tercer escenario se incorporó el exoesqueleto, pero aún sin conectar a una persona a los dispositivos de adquisición de señales. En lugar de señales en vivo, se reproducían secuencias de intención de la base de datos; éstas se enviaban a todo el flujo de trabajo donde se clasificaban, y la intención obtenida se mandaba al cRIO a través de la comunicación UDP, poniendo a prueba el controlador en tiempo real y el movimiento correcto del exoesqueleto.

Los resultados cuantitativos de estos tres modos de simulación se presentan en la sección 3.3.

Flujo de una sesión típica de uso

El cuarto escenario correspondió al uso completo del sistema HMI-exoesqueleto en lazo cerrado y en tiempo real. En esta etapa participaron 10 personas: cinco sujetos seleccionados del grupo inicial de 15 voluntarios, cuyos registros habían formado parte del entrenamiento de los clasificadores y que, por tanto, se denominaron sujetos conocidos; y cinco participantes adicionales, no incluidos previamente en la adquisición ni en el entrenamiento, denominados sujetos desco-

nocidos. En consecuencia, estos últimos permitieron evaluar la generalización del sistema frente a usuarios completamente nuevos.

La Figura 2.11 resume el flujo de una sesión típica de validación experimental, desde la preparación e instrumentación del participante hasta el registro de métricas y el cierre seguro del sistema.




Figura 2.11. Diagrama de flujo de una sesión típica de pruebas experimentales.

Como se resumió previamente en la Figura 2.11, el flujo de una sesión típica puede dividirse en las siguientes etapas:

1. Preparación e instrumentación.

Se le presentaba el protocolo al participante, se colocaban los sensores de EEG, sEMG e IMU, se verificaba la calidad de las señales y se realizaba una postura neutra inicial del exoesqueleto. Cabe destacar que, por razones de seguridad asociadas a las primeras pruebas de implementación y control en tiempo real, el usuario y el exoesqueleto se mantuvieron a una distancia segura entre sí.

2. Inicialización del sistema.

En la PC se ejecutaban los códigos encargados del flujo de información, desde la adquisición, la clasificación de intenciones y la comunicación con el cRIO. Así, el exoesqueleto pasaba a estado *Inactivo*.

3. Ejecución del protocolo en cuatro bloques.

Cada sesión se organizó en cuatro bloques experimentales que combinaban distintas condiciones de visión y carga externa. Estas variaciones se incorporaron para evaluar la robustez del sistema HMI-exoesqueleto ante cambios controlados en el contexto sensorial y mecánico de la tarea. La comparación entre ojos cerrados y ojos abiertos permitió analizar el efecto de modificar la retroalimentación visual disponible para el usuario, mientras que la comparación entre distintas cargas permitió modificar la demanda mecánica del movimiento sin cambiar la clase de intención solicitada. De esta manera, las condiciones experimentales buscaron introducir perturbaciones controladas para observar si el sistema mantenía un desempeño estable ante variaciones de ejecución, esfuerzo muscular y evidencia cinemática [57, 58]. A diferencia de utilizar únicamente la pesa “pequeña” de 0.88 kg, también se empleó una pesa denominada como “grande” de 1.2 kg, siguiendo la correspondencia que se describe a continuación:

- **OC_pequeña:** ejecución con ojos cerrados y una pesa pequeña como carga.
- **OC_grande:** ejecución con ojos cerrados y una pesa grande como carga.
- **OA_grande:** ejecución con ojos abiertos y una pesa grande como carga.
- **OC_nada:** ejecución con ojos cerrados y sin pesa.

En cada bloque se realizaron 10 repeticiones de las secuencias de flexión y extensión establecidas en el protocolo, las cuales fueron solicitadas en un orden aleatorio. La única modificación con respecto a la fase de adquisición de señales para el entrenamiento recayó en la duración de la fase de mantenimiento de la acción, ya no quedó fija en 2 segundos, sino que se asigna de forma aleatoria entre 2 a 5 segundos. Esta variabilidad introdujo una dinámica más cercana a un uso real, en la que el usuario no conocía de antemano el tiempo exacto durante el cual debe ejecutar la acción.

4. **Registro de métricas y cierre de sesión.** Al finalizar cada bloque se almacenaron los registros de la PC y del cRIO. A partir de estos datos se calculó, para cada condición experimental, la precisión media y la sensibilidad media de los clasificadores, además de las latencias medias entre el inicio de la ventana de datos y la ejecución del movimiento asistido. Finalmente, con el exoesqueleto en la postura neutra, se deshabilitaban los actuadores y se retiraban los sensores del participante.

Específicamente, se almacenaron los valores temporales correspondientes al inicio y final de cada ventana analizada, la señal de tiempo de referencia, la latencia asociada al procesamiento de la ventana de señales, la latencia requerida para obtener la referencia de comando enviada al controlador, y la latencia medida desde el momento en que la señal ingresaba al controlador hasta que se generaba la orden de movimiento del exoesqueleto. En cuanto a las variables no temporales, se registraron la intención cruda, el estado del sistema, la intención filtrada, la posición objetivo calculada enviada al exoesqueleto, la posición actual leída del exoesqueleto y el error entre estas dos últimas posiciones.

2.5. Análisis estadístico

Finalmente, en esta última sección de la metodología, se presentan los resultados de la evaluación final, los cuales se analizaron mediante un enfoque descriptivo e inferencial. Para cada sujeto se obtuvo una medición por bloque experimental, es decir un resultado de las cuatro condiciones: ojos cerrados con pesa pequeña, ojos cerrados con pesa grande, ojos abiertos con pesa grande y ojos cerrados sin pesa; calculando para cada bloque la precisión media, la sensibilidad media y la latencia media del sistema. Los sujetos se agruparon en dos niveles según la capacidad de generalización del modelo: sujetos conocidos, que participaron en la fase de entrenamiento, y sujetos desconocidos, que no fueron considerados durante dicha fase.

Primero, se obtuvieron las estadísticas descriptivas por condición y grupo, media y desviación estándar. Adicionalmente, se estimaron intervalos de confianza al 95 % (IC95 %) para las medias de cada celda grupo-condición, mediante remuestreo bootstrap a nivel de sujeto con 5000 remuestreos. Este procedimiento permite aproximar la variabilidad de un estimador a partir de los datos observados. En este trabajo, el remuestreo se realizó por sujeto para conservar juntas sus mediciones repetidas y preservar la dependencia intra-sujeto. Esta estrategia permitió obtener intervalos más robustos ante el tamaño reducido de la muestra final.

Para evaluar el efecto de la condición experimental, el nivel de generalización y su posible interacción sobre el desempeño y la latencia, se ajustaron modelos lineales mixtos con intercepto aleatorio por sujeto. En estos modelos, la condición se consideró como un factor intra-sujeto; y el grupo, si era conocido o desconocido, se tomó como un factor inter-sujeto, evaluando sus efectos principales y la interacción condición-grupo. Cuando se identificaron efectos relevantes, se realizaron comparaciones planificadas, específicamente diferencias entre condiciones dentro de cada grupo y diferencias entre grupos dentro de cada condición. Para controlar

el error asociado a comparaciones múltiples, los valores p se ajustaron utilizando el método de Holm-Bonferroni.

Finalmente, se exploró el posible compromiso entre desempeño y tiempo de respuesta mediante una gráfica de dispersión precisión-latencia por bloque y grupo; y un análisis de correlación a nivel intra-sujeto, considerando tanto Pearson como Spearman. De manera complementaria, se evaluó un ajuste formal de precisión en función de la latencia mediante un modelo mixto, incluyendo intercepto aleatorio por sujeto, para considerar la dependencia de las mediciones dentro de cada participante.

03

Resultados

En este Capítulo se presentan los resultados obtenidos a partir de la metodología descrita en el Capítulo 2, desde el procesamiento de las señales hasta la validación del sistema HMI-exoesqueleto, mostrando cómo cada etapa del proyecto contribuye al desempeño final del sistema de detección de intenciones y control de asistencia.

Como etapa inicial del desarrollo, se consolidó la base de datos multimodal obtenida durante la adquisición. En total, se completaron registros correspondientes a 15 voluntarios, con dos sesiones experimentales por participante y tres bloques de movimiento por sesión. Las señales de EEG, sEMG e IMU fueron almacenadas junto con sus marcadores temporales y metadatos de sesión, permitiendo continuar con las etapas de sincronización, segmentación, extracción de características y entrenamiento descritas en las secciones posteriores.

3.1. Optimización del modelo y selección de configuración

En esta etapa, con base en el procedimiento de optimización descrito en la Sección 2.3, se presentan los resultados de la optimización incremental realizada para definir los parámetros de entrenamiento de los clasificadores jerárquicos L1 (reposo vs movimiento) y L2 (flexión vs extensión de hombro). Inicialmente, se llevó a cabo la optimización de los parámetros de segmentación temporal para definir el tamaño de ventana y el porcentaje de solapamiento óptimos, con el fin de balancear el rendimiento del sistema y su factibilidad computacional en escenarios de operación en tiempo real. Como resultado de esta optimización, se seleccionó una ventana de 1.25 s con solape de 0.75, al mostrar el mejor compromiso entre métricas de desempeño, presentado en la Tabla 3.1. Esta configuración fue adoptada como base para los análisis posteriores.

Posteriormente, para L2 se redefinió el bloque basado en CSP, manteniendo la misma parametrización temporal e incorporando la optimización del banco de

subbandas empleado para el análisis en frecuencia. En la Tabla 3.2, BW representa el ancho de banda de las subbandas, FOV el factor de solapamiento entre subbandas y n_{CSP} el número de componentes CSP retenidos. La columna objetivo resume el valor de la función objetivo utilizada durante la optimización, mientras que las métricas de exactitud, F1 y exactitud balanceada permiten comparar el desempeño de la configuración seleccionada. A partir de estos parámetros, se construyó el banco CSP utilizado durante el entrenamiento y la evaluación del clasificador L2, esta tabla se encuentra en el Apéndice E.

Tabla 3.1. Mejor configuración de segmentación identificada en la optimización inicial (L1).

Ventana (s)	Solap.	$n_{\text{caract.}}$	Exactitud	F1 macro	Exactitud bal.	Pliegues
1.25	0.75	64	0.8288	0.8273	0.8284	5

Nota. Solap.: fracción de solapamiento entre ventanas consecutivas; $n_{\text{caract.}}$: número de características seleccionadas; F1 macro: promedio macro de *F1-score*; Exactitud bal.: exactitud balanceada; Pliegues: número de particiones generadas mediante validación LOSuO, dejando un sujeto completo fuera en cada iteración.

Tabla 3.2. Configuración seleccionada para el bloque CSP en L2 y desempeño obtenido durante su optimización.

Parámetro	Valor	Métrica	Valor
Ancho de subbanda (BW)	8 Hz	Función objetivo	0.7540
Solapamiento entre subbandas (FOV)	0.25	Exactitud media	0.7755
Componentes por subbanda (n_{CSP})	2	F1 medio	0.7278
Duración de ventana	1.25 s	Exactitud balanceada media	0.7674
Solapamiento temporal	0.75	Tiempo medio por pliegue	7.4114 s

Nota. CSP: patrones espaciales comunes; BW: ancho de las subbandas; FOV: fracción de solapamiento entre subbandas; n_{CSP} : número de componentes CSP retenidos por subbanda. Las métricas corresponden al promedio obtenido durante la validación estratificada de cinco pliegues.

Con los parámetros de segmentación y del bloque CSP fijados, se realizó una

búsqueda gruesa de hiperparámetros del clasificador SVM para L1 y L2. En ambos niveles, el mejor desempeño se obtuvo con una SVM lineal con un parámetro de regularización $C = 0.1$, presentado en la Tabla 3.3. Por lo que esta configuración fue la adoptada para los modelos finales integrados al sistema en tiempo real.

En cuanto a la selección de entradas multimodales, se eligieron los cinco bloques de señales con mejor comportamiento global en el protocolo. Estos bloques corresponden a características de EEG, de sEMG del sistema BioSignals-Plux (sEMG_BIO), de sEMG del brazalete Myo (sEMG_MYO), de aceleración (IMU_Accel) y giroscopio (IMU_Gyro), excluyendo las características de orientación (IMU_Orient). Finalmente, es necesario hacer notar que parte de estas decisiones de optimización fueron presentadas en el Congreso Nacional de Ingeniería Biomédica (CNIB) 2025 [59]. Con base en los hallazgos reportados en dicha publicación, se decidió no realizar la última etapa de optimización de pesos por bloque, ya que no aportaba mejoras consistentes con el objetivo principal del sistema. No obstante, esta etapa podría ser útil en aplicaciones futuras con otros criterios de desempeño.

Tabla 3.3. Búsqueda gruesa de hiperparámetros SVM para los niveles L1 y L2.

Nivel	Kernel	C	Bal. acc. media $\pm$ DE
L1 (reposo vs mov.)	lineal	0.1	0.8375 ± 0.0009
L2 (flex vs ext.)	lineal	0.1	0.8405 ± 0.0028

Nota. Bal. acc.: exactitud balanceada; DE: desviación estándar. La última columna reporta la media y desviación estándar de la exactitud balanceada obtenida durante la búsqueda gruesa de hiperparámetros SVM.

3.2. Depuración de características y reducción de redundancias

Como se describió en la sección 2.2 se realizó un procedimiento para limpieza de redundancias. La Figura 3.1 muestra la distribución de características por modalidad en L1 antes y después de la limpieza. Como se muestra en la Tabla 3.4, a partir de 128 características iniciales, el procedimiento redujo el conjunto a 75 características. Esto representa una reducción aproximada del 41 % de las variables originales.

Tabla 3.4. Número de características por bloque antes y después de la limpieza de redundancias.

Bloque	L1		L2	
	Antes	Después	Antes	Después
EEG	10	10	18	18
sEMG_BIO	22	12	24	14
sEMG_MYO	72	38	62	32
IMU	24	15	24	15
Total	128	75	128	79

De forma similar, la Figura 3.2 muestra los resultados para L2. En este caso, partiendo también de 128 características, el proceso de limpieza permitió reducirlas a 79, lo que representa una disminución aproximada del 38 % del total, como se aprecia en la Tabla 3.4.

En el Apéndice G se incluye la lista detallada de características que se conservaron tras el proceso de limpieza, con el propósito de mostrar las variables concretas que participan en el entrenamiento de los clasificadores. No se discute cada característica de manera individual, pero la información completa se deja disponible en los anexos para facilitar la replicación del estudio y futuras comparaciones.




Figura 3.1. Comparación gráfica antes y después de la limpieza de redundancias para la etapa L1.




Figura 3.2. Comparación gráfica antes y después de la limpieza de redundancias para la etapa L2.

3.3. Validación progresiva del sistema en simulación

A continuación se muestran los resultados divididos en los tres bloques de simulación presentados en la sección de plataforma experimental [2.4.3](#).

3.3.1. Simulación *offline* con base de datos, sin exoesqueleto

Los sujetos presentados en esta primera simulación se seleccionaron como casos representativos para verificar el funcionamiento progresivo del sistema bajo distintos niveles de generalización. En particular, se eligieron registros completos, con sincronización adecuada entre modalidades, marcadores temporales consistentes y ejecución del protocolo sin incidencias relevantes. Por tanto, la selección de estos sujetos tuvo como objetivo comprobar la continuidad del flujo de procesamiento, clasificación y generación de intención en condiciones representativas antes de avanzar hacia las pruebas *online* y con exoesqueleto.

Para la primera fase de pruebas del sistema HMI en modo *offline*, se emplearon bases de datos pregrabadas como entrada, sin conexión con el exoesqueleto, con el objetivo de evaluar el desempeño del clasificador jerárquico de intenciones.

Los resultados cuantitativos de las primeras pruebas se muestran en la Tabla [3.5](#), donde el clasificador alcanzó precisiones y sensibilidad ponderados mayores a 0.92 en los tres casos de exploración. Las matrices de confusión correspondientes a estos tres escenarios se presentan en la Tabla [3.6](#), donde se aprecia un número alto de aciertos en las clases de reposo, flexión y extensión, con pocos errores de confusión entre movimientos opuestos.

Adicionalmente, se evaluó el efecto de las diferentes combinaciones de modalidades sensoriales utilizando la sesión perteneciente al sujeto 1, de la simulación anterior. Para esto, se consideraron siete configuraciones: sólo EEG, sólo sEMG, sólo IMU, y las combinaciones entre estos. Los valores obtenidos de precisión y sensibilidad ponderados para la clasificación jerárquica L1-L2 se resumen en la Ta-

Tabla 3.5. Resultados ponderados del primer bloque de simulaciones *offline* para los tres sujetos evaluados (denotados como S1, S2 y S16).

	Precisión	Sensibilidad
Sesión conocida (S2)	0.936	0.935
Sesión desconocida, persona conocida (S1)	0.928	0.923
Sesión desconocida, persona desconocida (S16)	0.926	0.926

Tabla 3.6. Matrices de confusión de las simulaciones para los sujetos 2, 1 y 16.**(a)** Sujeto 2

Clase real	Predicción		
	Reposo	Flexión	Extensión
Reposo	592	6	8
Flexión	25	244	0
Extensión	23	12	233

(b) Sujeto 1

Clase real	Predicción		
	Reposo	Flexión	Extensión
Reposo	594	20	17
Flexión	6	261	0
Extensión	9	38	218

(c) Sujeto 16

Clase real	Predicción		
	Reposo	Flexión	Extensión
Reposo	590	6	26
Flexión	17	247	0
Extensión	36	0	228

bla 3.7. En términos generales, las configuraciones donde se obtienen las mejores métricas resultan de la combinación completa de los tres bloques de características.

Tabla 3.7. Precisión y sensibilidad ponderadas para las diferentes combinaciones de modalidades del sujeto 1.

Mod.	L1		L2	
	Precisión	Sensibilidad	Precisión	Sensibilidad
Solo EEG	0.406	0.554	0.567	0.567
Solo sEMG	0.881	0.880	0.878	0.877
Solo IMU	0.877	0.877	0.860	0.860
EEG+IMU	0.855	0.854	0.845	0.845
EEG+sEMG	0.865	0.864	0.876	0.875
sEMG+IMU	0.915	0.915	0.903	0.903
EEG+sEMG+IMU	0.926	0.916	0.928	0.923

Analizando únicamente la sesión correspondiente al sujeto 1, utilizada en simulaciones anteriores y considerada desconocida por el algoritmo debido a que sus señales no formaron parte del entrenamiento, se obtuvieron los siguientes resultados. Sin conectar todavía el sistema al cRIO, la Figura 3.3 muestra en el panel superior la clase solicitada durante el protocolo, definida a partir de las indicaciones auditivas y los marcadores temporales, junto con las ventanas en las que el clasificador detectó intención de movimiento. La clase solicitada constituye una etiqueta experimental y no una medición cinemática independiente del movimiento ejecutado por el participante. En la gráfica central se presentan las latencias estimadas para cada detección, diferenciando entre la latencia debida a la clasificación del bloque de señales, la latencia asociada al procesamiento de la intención clasificada y la latencia total medida desde el inicio de la ventana hasta la posición que se mandaría al exoesqueleto; cabe resaltar que estas barras de latencias se ubican en el instante donde inicia la detección de la intención, que es la latencia adicional de procesamiento perteneciente a la configuración de los bloques

de extracción de características; estas latencias se interpretan a profundidad en la sección de discusión. Finalmente en la parte inferior, se muestra la trayectoria discreta “ q_{goal} ” y la referencia suave que sería enviada al exoesqueleto “ q_{ref} ”, evidenciando la secuencia de movimientos de flexión y extensión que el sistema generaría a partir de la decisión de la intención.

El desempeño del clasificador jerárquico en esta sesión se resume mediante la matriz de confusión de la Tabla 3.8 y el reporte de clasificación en la Tabla 3.9.




Figura 3.3. Resultados de simulación *offline* con sesión perteneciente al sujeto 1.

Tabla 3.8. Matriz de confusión para la simulación *offline* de la sesión del sujeto 1.

Clase real	Predicción		
	Reposo	Flexión	Extensión
Reposo	592	6	8
Flexión	25	244	0
Extensión	23	12	233

Tabla 3.9. Reporte de clasificación para la simulación *offline* de la sesión del sujeto 1.

Clase	Precisión	Sensibilidad	<i>F1-score</i>	Soporte
Reposo	0.925	0.977	0.950	606
Flexión	0.931	0.907	0.919	269
Extensión	0.967	0.869	0.916	268
<i>Exactitud global</i>		0.935		1143
<i>Macro promedio</i>	0.941	0.918	0.928	1143
<i>Promedio ponderado</i>	0.936	0.935	0.935	1143

3.3.2. Simulación *online* con sujeto, sin exoesqueleto

En la segunda simulación se evaluó el desempeño del sistema en un escenario *online*, con la adquisición en tiempo real y la participación del sujeto 2 conectado al sistema, manteniendo todavía el exoesqueleto desconectado. El sujeto utilizado en esta prueba fue seleccionado por contar con un registro completo y estable durante la adquisición, así como por haber seguido adecuadamente las indicaciones del protocolo, lo que permitió evaluar la operación *online* del sistema sin introducir fallas técnicas ajenas al flujo de clasificación. En la Figura 3.4 se muestran los resultados obtenidos en este segundo bloque. El reporte por clase de la Tabla 3.11 muestra una sensibilidad elevada para la clase de reposo (0.945), mientras que se observan valores menores para las clases de movimiento, en particular para la

extensión (0.764). De manera consistente, la matriz de confusión de la Tabla 3.10 evidencia que una fracción de los errores asociados a flexión y extensión tienden a confundirse con la clase de reposo.

En términos temporales, el análisis de latencias para esta segunda simulación mostró una media de 51.7 ms y en el percentil 95 de 116.9 ms, como se puede observar en la segunda gráfica de la Figura 3.4. Esta figura permite visualizar el funcionamiento descrito en los resultados de la simulación previa, con la diferencia de que en este caso las señales son adquiridas y clasificadas en tiempo real. En particular, en las pruebas iniciales se observó que los resultados eran más bajos en la operación *online* y fue necesario reducir el umbral de decisión para el movimiento de extensión en L2, pasando de 0.60 a 0.50.

Tabla 3.10. Matriz de confusión para la simulación *online* de la sesión del sujeto 2.

Clase real	Predicción		
	Reposo	Flexión	Extensión
Reposo	568	18	15
Flexión	34	220	11
Extensión	50	12	201

Tabla 3.11. Reporte de clasificación para la simulación *online* de la sesión del sujeto 2.

Clase	Precisión	Sensibilidad	<i>F1-score</i>	Soporte
Reposo	0.871	0.945	0.907	601
Flexión	0.880	0.830	0.854	265
Extensión	0.885	0.764	0.820	263
<i>Exactitud global</i>		0.876		1129
<i>Macro promedio</i>	0.879	0.847	0.860	1129
<i>Promedio ponderado</i>	0.877	0.876	0.874	1129




Figura 3.4. Resultados de simulación *online* con sesión perteneciente al sujeto 2.




Figura 3.5. Acercamiento de la simulación *online* donde se observan indecisiones del clasificador y conmutaciones breves en la referencia discreta.

Además, en este modo *online* se observó un efecto característico de la operación en tiempo real: cuando el clasificador presentaba indecisión, se producían alternancias breves entre reposo y movimiento. Este comportamiento se aprecia de forma general en la Figura 3.4 y con mayor detalle en la Figura 3.5, donde los cambios rápidos de la intención detectada generan conmutaciones entre objetivos discretos de posición. A pesar de estas variaciones, la referencia suavizada tiende a atenuar los cambios abruptos antes de ser enviada como comando de movimiento.

Este resultado permitió identificar la necesidad de utilizar filtrado temporal de la intención y reglas de estabilidad antes de transmitir los comandos hacia la máquina de estados del exoesqueleto.

3.3.3. Simulación con exoesqueleto en lazo cerrado

En la tercera simulación se evaluó el funcionamiento del sistema en un esquema de lazo cerrado, donde la intención de movimiento se generó a partir de una sesión que ya había sido pre-grabada, como en la simulación 1. La diferencia es que una vez clasificada la intención, se utilizó para accionar el exoesqueleto mediante el controlador en el sistema embebido.

La Figura 3.6 muestra el resultado gráfico utilizando una sesión pre-grabada del sujeto 2. Al igual que en resultados anteriores, en la parte superior se presentan los periodos de flexión, extensión y reposo solicitados, así como la intención estimada durante cada fase. En la gráfica central se muestran las latencias de detección por evento, obteniendo una media de 105.5 ms y el percentil 95 de 161.0 ms, añadiendo la latencia del controlador de impedancia. En la parte inferior se muestran la trayectoria objetivo y la trayectoria de referencia, junto con la trayectoria medida por el sistema, es decir, la posición articular registrada. Esto permite visualizar el desempeño del seguimiento del robot durante las transiciones entre posiciones objetivo.




Figura 3.6. Resultados de simulación *offline* con base de datos perteneciente al sujeto 2 y conexión de la HMI con el exoesqueleto.

En términos de desempeño, los reportes de clasificación y la matriz de confusión de esta sesión son los previamente presentados en las Tablas 3.8 y 3.9, respectivamente. Además, en esta simulación se añade el desglose de latencias temporales de clasificación específicas por movimiento, mostradas en la Tabla 3.12.

Tabla 3.12. Resumen de latencias de clasificación para decisiones estables para la Simulación 3.

Condición	n	Media (ms)	Mediana (ms)	p_{95} (ms)
Total	81	105.5	95.0	161.0
Reposo	41	118.3	141.0	162.0
Flexión	20	88.1	90.5	101.8
Extensión	20	93.6	95.0	122.5

3.4. Resultados experimentales en tiempo real

En la etapa de experimentación se evaluó el funcionamiento del sistema completo en operación *online*, en tiempo real y en lazo cerrado, integrando la adquisición multimodal de señales, la clasificación jerárquica L1-L2, la máquina de estados, la generación de referencias de posición y el control del exoesqueleto bajo criterios apropiados de seguridad. A diferencia de las simulaciones presentadas en la sección anterior, en esta fase se realizaron pruebas con participantes instrumentados, de los cuales cinco regresaron al laboratorio para operar el sistema final bajo condiciones controladas. Adicionalmente, se incluyeron otros cinco participantes nuevos en el protocolo, cuyas señales eran desconocidas para el algoritmo.

Como se explicó en la sección de metodología 2.4.4, se realizó un protocolo compuesto por cuatro bloques de adquisición, definidos por las siguientes variantes: ojos cerrados con pesa pequeña, ojos cerrados con pesa grande, ojos abiertos con pesa grande y ojos cerrados sin pesa. En cada bloque se documentó el de-

sempaño del sistema mediante: (i) una figura similar a la presentada en la tercera simulación, (ii) una matriz de confusión, (iii) un reporte de clasificación, y (iv) un reporte de latencias. Estos elementos permiten caracterizar el comportamiento del sistema tanto desde la perspectiva de la clasificación como en términos de desempeño temporal y capacidad de seguimiento.

Los resultados globales de esta fase se resumen en las Tablas 3.13-3.15. La Tabla 3.13 presenta la precisión media obtenida por sujeto y por bloque, separando el análisis entre sujetos conocidos por el algoritmo y sujetos desconocidos. De forma análoga, la Tabla 3.14 reporta la sensibilidad media para las mismas condiciones, permitiendo comparar el desempeño promedio del sistema bajo los distintos escenarios del protocolo. Finalmente, la Tabla 3.15 muestra la latencia media en milisegundos por sujeto y por bloque, proporcionando una medida directa del retardo promedio por respuesta del sistema en operación en tiempo real.

Tabla 3.13. Precisión media por sujeto y condición experimental, separando sujetos conocidos y desconocidos.

Sujeto	Ojos cerrados + pesa pequeña	Ojos cerrados + pesa grande	Ojos abiertos + pesa grande	Ojos cerrados + sin pesa
Conocidos				
Sujeto 1	0.909	0.893	0.810	0.874
Sujeto 5	0.879	0.749	0.881	0.802
Sujeto 4	0.858	0.868	0.896	0.930
Sujeto 2	0.884	0.837	0.891	0.888
Sujeto 13	0.865	0.792	0.886	0.904
Media $\pm$ DE	0.879 $\pm$ 0.020	0.828 $\pm$ 0.058	0.873 $\pm$ 0.036	0.880 $\pm$ 0.048
Desconocidos				
Sujeto 16	0.879	0.855	0.906	0.857
Sujeto 17	0.875	0.746	0.861	0.836
Sujeto 18	0.869	0.853	0.867	0.766
Sujeto 19	0.837	0.857	0.889	0.826
Sujeto 20	0.935	0.940	0.902	0.915
Media $\pm$ DE	0.879 $\pm$ 0.035	0.850 $\pm$ 0.069	0.885 $\pm$ 0.020	0.840 $\pm$ 0.054

De forma general, las Tablas 3.13, 3.14 y 3.15 muestran que el sistema mantuvo un desempeño comparable entre sujetos conocidos y desconocidos. En precisión

Tabla 3.14. Sensibilidad media por sujeto y condición experimental, separando sujetos conocidos y desconocidos.

Sujeto	Ojos cerrados + pesa pequeña	Ojos cerrados + pesa grande	Ojos abiertos + pesa grande	Ojos cerrados + sin pesa
Conocido				
Sujeto 1	0.878	0.844	0.748	0.676
Sujeto 5	0.873	0.670	0.874	0.765
Sujeto 4	0.856	0.852	0.903	0.911
Sujeto 2	0.841	0.778	0.842	0.813
Sujeto 13	0.757	0.745	0.842	0.899
Media $\pm$ DE	0.841 $\pm$ 0.049	0.778 $\pm$ 0.075	0.842 $\pm$ 0.058	0.813 $\pm$ 0.098
Desconocido				
Sujeto 16	0.866	0.850	0.898	0.876
Sujeto 17	0.863	0.722	0.813	0.764
Sujeto 18	0.863	0.787	0.723	0.595
Sujeto 19	0.774	0.876	0.881	0.824
Sujeto 20	0.931	0.930	0.900	0.909
Media $\pm$ DE	0.859 $\pm$ 0.056	0.833 $\pm$ 0.081	0.843 $\pm$ 0.076	0.794 $\pm$ 0.124

Tabla 3.15. Latencia media (ms) por sujeto y condición experimental, separando sujetos conocidos y desconocidos.

Sujeto	Ojos cerrados + pesa pequeña	Ojos cerrados + pesa grande	Ojos abiertos + pesa grande	Ojos cerrados + sin pesa
Conocido				
Sujeto 1	34.5	46.3	43.3	36.2
Sujeto 5	76.0	58.1	53.5	53.7
Sujeto 4	59.0	43.5	57.0	59.5
Sujeto 2	54.2	50.85	51.95	49.6
Sujeto 13	47.3	55.5	54.0	49.0
Media $\pm$ DE	54.2 $\pm$ 15.280	50.85 $\pm$ 6.101	51.95 $\pm$ 5.170	49.6 $\pm$ 8.584
Desconocido				
Sujeto 16	67.7	50.3	53.8	46.3
Sujeto 17	46.1	59.0	61.8	54.2
Sujeto 18	60.0	50.6	62.8	63.3
Sujeto 19	50.7	49.0	67.7	57.6
Sujeto 20	44.9	55.0	53.6	48.5
Media $\pm$ DE	53.88 $\pm$ 9.743	52.78 $\pm$ 4.147	59.94 $\pm$ 6.118	53.98 $\pm$ 6.874

media, los sujetos conocidos presentaron valores promedio entre 0.828 y 0.880, mientras que los sujetos desconocidos se mantuvieron entre 0.840 y 0.885, dependiendo de la condición experimental. La condición de ojos cerrados con pesa grande concentró el valor promedio más bajo en sujetos conocidos, mientras que la condición de ojos abiertos con pesa grande presentó uno de los valores más altos en ambos grupos. Esto indica que las diferencias principales se relacionaron más con la condición experimental que con la pertenencia al grupo conocido o desconocido.

En sensibilidad media se observó un comportamiento similar, aunque con mayor variabilidad entre condiciones. Los sujetos conocidos presentaron valores promedio entre 0.778 y 0.842, mientras que los sujetos desconocidos se ubicaron entre 0.794 y 0.859. En ambos grupos, las condiciones con mayor demanda o cambio de contexto, como ojos cerrados con pesa grande y ojos cerrados sin pesa, tendieron a mostrar mayor variabilidad. En cuanto a la latencia media, los valores promedio se mantuvieron principalmente entre 49 y 60 ms para las distintas condiciones y grupos, lo que sugiere una respuesta temporal relativamente consistente durante la operación *online* del sistema HMI-exoesqueleto.

Además de los valores promedio por sujeto y condición, se analizaron ejemplos representativos de latencia durante la operación *online*. La Figura 3.7 muestra dos segmentos correspondientes a sesiones diferentes, seleccionados para ilustrar variaciones en el retardo de clasificación observado durante la operación del sistema. En la Figura 3.7(a) se aprecia un caso en el que la detección ocurre con menor retardo (≈ 300 ms) respecto a la fase de movimiento solicitada, mientras que en la Figura 3.7(b) se observa un caso con mayor retraso (≈ 1 s) antes de que la intención sea detectada de forma estable. Esta comparación permite visualizar que, aun cuando el clasificador genera decisiones correctas, el instante en que dichas decisiones se estabilizan puede variar entre sesiones.

Como complemento a los resultados globales presentados, se incluyen ejemplos representativos de sesiones experimentales completas en los Apéndices [K](#) y [L](#). Estos ejemplos corresponden a un sujeto conocido y a un sujeto desconocido para el algoritmo, respectivamente, y muestran el comportamiento temporal de la intención cruda, la intención filtrada, el estado de la máquina de estados, la referencia generada y la posición medida del exoesqueleto. Su propósito es ilustrar cómo las métricas globales se reflejan en la operación real del sistema durante bloques completos de experimentación.

Estos resultados se analizan más adelante en la discusión, comenzando con una visión comparativa general y, posteriormente, profundizando en las diferencias entre condiciones, así como en su relación con el comportamiento temporal y el seguimiento de la trayectoria.



(a) Ejemplo con latencias bajas (≈ 300 ms).(b) Ejemplo con latencia elevada (≈ 1 s).

Figura 3.7. Ejemplos de latencia en operación *online*. Se muestra el aumento de la latencia de clasificación entre dos sesiones diferentes.

3.5. Análisis estadístico del desempeño experimental

Con el fin de cuantificar el desempeño del sistema en la etapa de experimentación final, se analizaron tres métricas: precisión ponderada, sensibilidad ponderada y latencia media. Los resultados se agruparon por condición experimental y por tipo de generalización. Para cada condición se reportaron estadísticos descriptivos, intervalos de confianza y comparaciones entre grupos, así como un análisis de interacción condición-generalización. Las condiciones experimentales se presentan en el mismo orden en todas las figuras: OC_pequeña, OC_grande, OA_grande y OC_nada. Este orden se eligió para facilitar la comparación entre condiciones: primero se contrasta el efecto de aumentar la carga con ojos cerrados, después el efecto de abrir los ojos manteniendo la carga grande, y finalmente la condición sin carga externa como referencia.

Las Figuras 3.8 - 3.10 muestran las gráficas de interacción condición-generalización para las tendencias en métricas de precisión, sensibilidad y latencias, respectivamente. Estas figuras resumen en forma directa el comportamiento promedio de cada métrica a través de las cuatro condiciones, comparando el patrón entre sujetos conocidos y desconocidos. En cada gráfica se incluye el promedio por condición y su intervalo de confianza al 95 %, lo cual permite apreciar tanto la tendencia central como la variabilidad entre sujetos.

En cuanto a dispersión individual, las distribuciones de precisión, sensibilidad y latencia por condición y por grupo se muestran mediante diagramas de caja en las Figuras 3.11 a 3.13. Estas representaciones permiten apreciar la latencia central y la variabilidad intersujeto en cada condición al mostrar la dispersión de los valores individuales, tanto para el grupo de sujetos conocidos como para los sujetos desconocidos.

Visualmente, la precisión y la sensibilidad se mantuvieron en rangos comparables entre sujetos conocidos y desconocidos, aunque se observó mayor dispersión




Figura 3.8. Interacción de precisión entre grupo y condición. Las condiciones corresponden a: OC_pequeña, ojos cerrados con pesa pequeña; OC_grande, ojos cerrados con pesa grande; OA_grande, ojos abiertos con pesa grande; y OC_nada, ojos cerrados sin pesa.




Figura 3.9. Interacción de sensibilidad entre grupo y condición. Las condiciones corresponden a: OC_pequeña, ojos cerrados con pesa pequeña; OC_grande, ojos cerrados con pesa grande; OA_grande, ojos abiertos con pesa grande; y OC_nada, ojos cerrados sin pesa.




Figura 3.10. Interacción de latencia entre grupo y condición. Las condiciones corresponden a: OC_pequeña, ojos cerrados con pesa pequeña; OC_grande, ojos cerrados con pesa grande; OA_grande, ojos abiertos con pesa grande; y OC_nada, ojos cerrados sin pesa.




Figura 3.11. Distribución de la precisión por condición experimental y grupo de generalización. Las cajas representan la variabilidad entre sujetos para cada condición, mientras que los puntos individuales corresponden a los valores obtenidos por sujeto. Las condiciones corresponden a: OC_pequeña = ojos cerrados con pesa pequeña; OC_grande = ojos cerrados con pesa grande; OA_grande = ojos abiertos con pesa grande; OC_nada = ojos cerrados sin pesa.




Figura 3.12. Distribución de la sensibilidad por condición experimental y grupo de generalización. Las cajas representan la variabilidad entre sujetos para cada condición, mientras que los puntos individuales corresponden a los valores obtenidos por sujeto. Las condiciones corresponden a: OC_pequeña = ojos cerrados con pesa pequeña; OC_grande = ojos cerrados con pesa grande; OA_grande = ojos abiertos con pesa grande; OC_nada = ojos cerrados sin pesa.




Figura 3.13. Distribución de la latencia media por condición experimental y grupo de generalización. Las cajas representan la variabilidad entre sujetos para cada condición, mientras que los puntos individuales corresponden a los valores obtenidos por sujeto. Las condiciones corresponden a: OC_pequeña = ojos cerrados con pesa pequeña; OC_grande = ojos cerrados con pesa grande; OA_grande = ojos abiertos con pesa grande; OC_nada = ojos cerrados sin pesa.

en algunas condiciones, principalmente en aquellas asociadas con mayor demanda mecánica o cambio de contexto experimental. En el caso de la latencia, las distribuciones se agruparon en un intervalo relativamente estrecho y con amplio solapamiento entre grupos, lo que sugiere una respuesta temporal consistente durante la operación *online* del sistema.

Además, se calcularon intervalos de confianza al 95 % para cada métrica en cada condición y grupo. Los resúmenes numéricos con media e IC95 % se incluyen en el Apéndice [H](#).

Para tener en cuenta la dependencia entre mediciones repetidas de un mismo sujeto, se ajustaron modelos con intercepto aleatorio por sujeto para cada métrica. Los resúmenes completos de los modelos se incluyen en el Apéndice [I](#), puesto que su propósito principal es respaldar la inferencia estadística y evidenciar la ausencia de significancia de efectos.

Para complementar los resultados descriptivos e inferenciales, se realizaron comparaciones *post-hoc* entre grupos dentro de cada condición, así como entre condiciones dentro de cada grupo. Los valores de significancia fueron ajustados mediante el método de Holm-Bonferroni para controlar el error por comparaciones múltiples. Los resultados correspondientes a precisión, sensibilidad y latencia se presentan en las Tablas [3.16](#), [3.17](#) y [3.18](#), respectivamente.

En los modelos mixtos no se observaron efectos significativos del grupo ni de la interacción grupo-condición para precisión, sensibilidad o latencia. La principal tendencia correspondió a una reducción de precisión en la condición OC_grande respecto a OC_pequeña dentro del grupo de sujetos conocidos; sin embargo, esta diferencia no se mantuvo después de aplicar la corrección por comparaciones múltiples. De forma similar, las tendencias observadas en sensibilidad y latencia no conservaron significancia tras el ajuste de Holm-Bonferroni.

Finalmente, se exploró el posible compromiso entre el desempeño y el tiempo

Tabla 3.16. Comparaciones *post-hoc* de precisión entre condiciones y grupos.

Contraste	Efecto	SD	p	p_{Holm}
grupo desconocidos - conocidos @ OC_pequeña	4.07×10^{-16}	0.0258	1.0000	1.0000
grupo desconocidos - conocidos @ OC_grande	0.0224	0.0258	0.3853	1.0000
grupo desconocidos - conocidos @ OA_grande	0.0122	0.0258	0.6364	1.0000
grupo desconocidos - conocidos @ OC_nada	-0.0396	0.0258	0.1249	0.9989
OC_grande - OC_pequeña @ grupo=conocidos	-0.0512	0.0219	0.0196	0.1961
OA_grande - OC_pequeña @ grupo=conocidos	-0.0062	0.0219	0.7775	1.0000
OC_nada - OC_pequeña @ grupo=conocidos	0.0006	0.0219	0.9782	1.0000
OC_grande - OC_pequeña @ grupo=desconocidos	-0.0288	0.0219	0.1893	1.0000
OA_grande - OC_pequeña @ grupo=desconocidos	0.0060	0.0219	0.7845	1.0000
OC_nada - OC_pequeña @ grupo=desconocidos	-0.0390	0.0219	0.0755	0.6792

Nota. Efecto = diferencia estimada entre los niveles comparados; SD = desviación estándar; p = valor sin ajustar; p_{Holm} = valor ajustado por Holm–Bonferroni. Los contrastes “grupo desconocidos - conocidos @ condición” comparan grupos dentro de cada condición; los contrastes “condición - OC_pequeña @ grupo” comparan condiciones contra OC_pequeña dentro de cada grupo.

Tabla 3.17. Comparaciones *post-hoc* de sensibilidad entre condiciones y grupos.

Contraste	Efecto	SD	p	p_{Holm}
grupo desconocidos - conocidos @ OC_pequeña	0.0184	0.0455	0.6857	1.0000
grupo desconocidos - conocidos @ OC_grande	0.0552	0.0455	0.2248	1.0000
grupo desconocidos - conocidos @ OA_grande	0.0012	0.0455	0.9789	1.0000
grupo desconocidos - conocidos @ OC_nada	-0.0192	0.0455	0.6728	1.0000
OC_grande - OC_pequeña @ grupo=conocidos	-0.0632	0.0382	0.0984	0.8852
OA_grande - OC_pequeña @ grupo=conocidos	0.0008	0.0382	0.9833	1.0000
OC_nada - OC_pequeña @ grupo=conocidos	-0.0282	0.0382	0.4608	1.0000
OC_grande - OC_pequeña @ grupo=desconocidos	-0.0264	0.0382	0.4899	1.0000
OA_grande - OC_pequeña @ grupo=desconocidos	-0.0164	0.0382	0.6680	1.0000
OC_nada - OC_pequeña @ grupo=desconocidos	-0.0658	0.0382	0.0853	0.8528

Nota. Efecto = diferencia estimada entre los niveles comparados; SD = desviación estándar; p = valor sin ajustar; p_{Holm} = valor ajustado por Holm–Bonferroni. Los contrastes “grupo desconocidos - conocidos @ condición” comparan grupos dentro de cada condición; los contrastes “condición - OC_pequeña @ grupo” comparan condiciones contra OC_pequeña dentro de cada grupo.

Tabla 3.18. Comparaciones *post-hoc* de latencia entre condiciones y grupos.

Contraste	Efecto	SD	p	p_{Holm}
grupo desconocidos - conocidos @ OC_pequeña	-0.32	4.7664	0.9465	1.0000
grupo desconocidos - conocidos @ OC_grande	1.93	4.7664	0.6855	1.0000
grupo desconocidos - conocidos @ OA_grande	7.99	4.7664	0.0937	0.9368
grupo desconocidos - conocidos @ OC_nada	4.38	4.7664	0.3581	1.0000
OC_grande - OC_pequeña @ grupo=conocidos	-3.35	4.0638	0.4097	1.0000
OA_grande - OC_pequeña @ grupo=conocidos	-2.25	4.0638	0.5798	1.0000
OC_nada - OC_pequeña @ grupo=conocidos	-4.60	4.0638	0.2577	1.0000
OC_grande - OC_pequeña @ grupo=desconocidos	-1.10	4.0638	0.7866	1.0000
OA_grande - OC_pequeña @ grupo=desconocidos	6.06	4.0638	0.1359	1.0000
OC_nada - OC_pequeña @ grupo=desconocidos	0.10	4.0638	0.9804	1.0000

Nota. Efecto = diferencia estimada entre los niveles comparados; SD = desviación estándar; p = valor sin ajustar; p_{Holm} = valor ajustado por Holm–Bonferroni. Los contrastes “grupo desconocidos - conocidos @ condición” comparan grupos dentro de cada condición; los contrastes “condición - OC_pequeña @ grupo” comparan condiciones contra OC_pequeña dentro de cada grupo.

de respuesta del sistema mediante una gráfica de dispersión y un análisis de correlación. La dispersión precisión-latencia se muestra en la Figura 3.14, mientras que los resultados numéricos de correlación se presentan en la Tabla 3.19. De manera complementaria, el modelo mixto que incorporó la latencia como predictor de la precisión tampoco mostró un efecto significativo (ver Apéndice J), por lo que no se observó evidencia de un compromiso sistemático entre desempeño y tiempo de respuesta dentro del rango evaluado.

Tabla 3.19. Correlación entre precisión y latencia a nivel intra-sujeto.

Método	r	p
Pearson	0.0395	0.8089
Spearman	0.0421	0.7963

Nota. r representa el coeficiente de correlación y p el valor de significancia estadística.




Figura 3.14. Relación entre precisión y latencia media del sistema en la etapa experimental. Cada punto representa un bloque experimental correspondiente a un sujeto y una condición, diferenciando entre sujetos conocidos y desconocidos para el algoritmo. La figura permite explorar visualmente si existe un compromiso entre el desempeño de clasificación y el tiempo de respuesta del sistema.

04

Discusión

En este Capítulo se discuten los resultados obtenidos a lo largo del proceso de desarrollo y validación del sistema HMI y el exoesqueleto. La discusión se organiza de forma progresiva, esto permite conectar los resultados cuantitativos con los retos de implementación práctica, destacando las implicaciones para generalización, estabilidad temporal y robustez operativa en escenarios cercanos a la aplicación real.

4.1. Implicaciones del diseño del modelo de detección

4.1.1. Balance entre resolución temporal y estabilidad de decisión

Los resultados de la optimización inicial sugieren que la configuración seleccionada ofrece un compromiso adecuado para el sistema implementado. Aunque de inicio podría esperarse que una ventana más pequeña redujera el retardo de decisión, en este caso la relación no es necesariamente directa, ya que el desempeño depende de la calidad y estabilidad temporal de las características extraídas de las distintas señales. Además, es necesario considerar las restricciones prácticas del *hardware* y la adquisición, como la frecuencia de muestreo, el ruido, la sincronización y el posible desfase entre dispositivos.

Con los equipos utilizados, ventanas demasiado cortas tendían a degradar la consistencia de las características, lo que podía aumentar la variabilidad inter-sujeto y generar decisiones más inestables. Por el contrario, ventanas más largas pueden mejorar la precisión, pero también incrementan el retardo efectivo para una aplicación práctica. En este sentido, la configuración adoptada conserva suficiente contenido temporal para discriminar las intenciones, mientras que el solapamiento permite actualizar la decisión con mayor frecuencia sin esperar la adquisición de un bloque completamente nuevo.

En la etapa de clasificación, la selección de una SVM lineal resulta coherente con la operación en tiempo real. Este tipo de modelo mantiene un costo compu-

tacional bajo y facilita una inferencia rápida, lo cual es relevante al integrarse con la adquisición multimodal, la extracción de características, la máquina de estados y el control del exoesqueleto. Así, las optimizaciones no solo priorizaron el rendimiento promedio, sino también el balance con la viabilidad temporal de la detección completa.

Por último, en la optimización de bloques se dejaron fuera características que no aportaban mejoras consistentes o que presentaban una fuerte relación con señales precursoras, como ocurrió con algunas variables de orientación derivadas de la IMU. Además, no se continuó con la optimización de ponderación por modalidad, ya que su beneficio no justificaba el aumento de complejidad ni el posible riesgo de sobreajuste. En resumen, este proceso permitió obtener una configuración más compacta y funcional para el sistema, aunque también deja abierta la necesidad de considerar estrategias futuras de calibración y adaptación ante variaciones en la colocación de electrodos, ruido inducido por movimiento y diferencias entre sujetos.

4.1.2. Aporte de la reducción de redundancias y de la fusión multimodal

Los resultados de la limpieza de redundancias sugieren que el procedimiento no eliminó modalidades completas, sino información repetida dentro de cada bloque de características. Esto es importante porque, en un sistema multimodal, reducir dimensionalidad no debe interpretarse necesariamente como una pérdida de información sensorial, sino como una forma de conservar representaciones más compactas y menos correlacionadas para el clasificador.

En las señales musculares, especialmente en el bloque de sEMG del MYO Armband, era esperable encontrar un grado importante de redundancia. La colocación del brazalete alrededor del brazo hace que varios de sus canales registren

patrones de activación relacionados durante movimientos relativamente simples de flexión y extensión de hombro. Además, al calcular múltiples descriptores en tiempo y frecuencia por canal, algunas características tienden a capturar aspectos similares de la señal. De este modo, la reducción observada en este bloque puede interpretarse como una compactación del espacio de entrada, más que como una disminución del aporte muscular al sistema.

Algo similar ocurre con las características de IMU. La cinemática del segmento durante el grado de libertad estudiado es relativamente estructurada, por lo que ciertas componentes lineales y angulares pueden presentar relaciones consistentes entre sí. En este caso, la reducción de redundancias ayudó a evitar que el clasificador recibiera varias versiones de una misma tendencia cinemática, manteniendo únicamente aquellas variables que aportaban información menos repetida.

El bloque de sEMG del Biosignalsplux tiene una interpretación particular, ya que los electrodos se colocaron directamente sobre musculatura relevante para el movimiento de hombro. Por esta razón, aunque también se identificaron características redundantes, este bloque conserva un papel importante dentro del sistema. La reducción en este caso no implica que la señal concentrada pierda relevancia, sino que no todos los descriptores calculados sobre ella son necesarios para representar la activación muscular asociada al movimiento.

Por otro lado, el bloque de EEG se mantuvo sin reducción. Esta decisión es metodológicamente coherente con el objetivo del proyecto, ya que una parte importante del sistema busca preservar el aporte cortical dentro de la detección de intención. Además, el conjunto de características de EEG era más compacto desde su definición inicial, por lo que conservarlo completo permitió mantener la contribución de la información cortical sin incrementar de manera excesiva la dimensionalidad total del modelo.

La combinación de modalidades se mantuvo porque cada señal representa una

etapa diferente y parcialmente complementaria del proceso motor. En consecuencia, el deterioro temporal de una modalidad por ruido, variaciones de colocación, fatiga o ejecución irregular puede ser compensado parcialmente por la información restante. Esta complementariedad también se reflejó en la comparación por bloques, donde la fusión EEG-sEMG-IMU obtuvo un desempeño superior al de las modalidades aisladas en la sesión analizada. No obstante, estos resultados no implican que todas las modalidades contribuyan de manera idéntica ni constante entre usuarios y condiciones.

En conjunto, la limpieza de redundancias permitió obtener una representación multimodal más compacta y manejable, reduciendo el riesgo de sobreajuste y facilitando la integración con un flujo de clasificación en tiempo real. No obstante, este procedimiento también debe interpretarse con cautela, ya que eliminar características altamente correlacionadas mejora la estabilidad del espacio de entrada, pero no resuelve por completo problemas como variabilidad inter-sujeto, cambios en la colocación de sensores o ruido inducido por movimiento. Es así que, en trabajos futuros esta etapa podría complementarse con estrategias de selección más adaptativas o calibración específica por usuario.

4.2. Implicaciones de la validación progresiva del sistema

Las simulaciones realizadas antes de la experimentación final fueron una etapa clave para transformar el clasificador entrenado *offline* en un sistema operativo integrado con el exoesqueleto. Su importancia no radica únicamente en verificar el desempeño del modelo, sino en permitir una validación progresiva del flujo completo: primero con datos pregrabados, después con señales adquiridas en vivo y finalmente con comunicación hacia el cRIO y movimiento físico del robot.

4.2.1. Hallazgos de la simulación *offline*

La primera simulación permitió comprobar que el clasificador jerárquico podía reproducir de manera consistente las decisiones de intención a partir de bases de datos previamente adquiridas. Esta etapa funcionó como una verificación inicial del procesamiento, el ventaneo, la extracción de características y la lógica L1–L2, sin introducir todavía la variabilidad propia de la adquisición en vivo ni los riesgos asociados al movimiento del exoesqueleto.

4.2.2. Retos observados en la simulación *online*

La segunda simulación representó un incremento importante en complejidad, ya que incorporó señales adquiridas en tiempo real. A diferencia de la evaluación *offline*, en este caso aparecieron efectos propios de la operación continua, como fluctuaciones entre ventanas, indecisiones del clasificador y variaciones asociadas al estado del participante durante la adquisición. Esto mostró que el desempeño del sistema no depende únicamente de la precisión del modelo, sino también de la estabilidad temporal de sus salidas y de la capacidad del sistema *online* para manejar decisiones consecutivas.

Un hallazgo importante de esta etapa fue que la operación *online* puede requerir ajustes de calibración que no son evidentes durante la evaluación *offline*. En particular, los umbrales de decisión y el filtrado temporal de la intención se vuelven elementos críticos para evitar que pequeñas fluctuaciones del clasificador se propaguen hacia la máquina de estados y el generador de referencias. Esto refuerza la necesidad de contemplar estrategias de calibración previa o adaptación inter-sesión en sistemas HMI orientados a operación real.

4.2.3. Efecto de la integración del exoesqueleto en lazo cerrado

La tercera simulación permitió validar la conexión entre la HMI y el exoesqueleto sin exponer todavía a un usuario a la interacción física directa con el robot. Esta etapa fue especialmente relevante porque permitió observar cómo las decisiones discretas del clasificador se transformaban en estados, referencias suaves y movimiento articular medido. De esta forma, la simulación con el funcionamiento del exoesqueleto sirvió como puente entre la clasificación de la intención y la ejecución física de la asistencia, verificando que la comunicación UDP, la máquina de estados, el generador de trayectoria y el controlador pudieran operar de forma coordinada.

En conjunto, las simulaciones funcionaron como una estrategia de validación incremental. Cada etapa añadió una fuente adicional de realismo y complejidad: primero la reproducción de datos, después la adquisición *online* y finalmente el accionamiento del exoesqueleto. Esta progresión permitió identificar ajustes necesarios antes de las pruebas finales, particularmente en la estabilidad de la intención filtrada, los umbrales de decisión, la generación de referencias y el registro de latencias. De este modo, más que ser una fase secundaria, las simulaciones constituyeron una capa metodológica de seguridad y depuración para reducir riesgos durante la experimentación en lazo cerrado.

4.3. Interpretación del desempeño experimental en tiempo real

La etapa de experimentación representó la validación más completa del sistema propuesto, ya que integró en un mismo flujo la adquisición multimodal en vivo, la clasificación jerárquica, la comunicación con el cRIO, la máquina de estados, la generación de referencias y el control del exoesqueleto. A diferencia de las

simulaciones, esta fase incorporó simultáneamente la variabilidad fisiológica del usuario, las condiciones reales de adquisición, la operación *online* y la respuesta física del robot. Por ello, su relevancia no se limita a confirmar el desempeño del clasificador, sino a verificar que la arquitectura completa pudiera operar de forma coordinada bajo condiciones experimentales controladas.

4.3.1. Robustez ante variación de condiciones

Los resultados presentados en el Capítulo 3 sugieren que el sistema mantuvo un comportamiento funcional a pesar de los cambios introducidos por el protocolo, como la variación de carga externa, la condición de ojos abiertos o cerrados y la inclusión de sujetos no vistos previamente por el algoritmo. Esto es importante porque, en un escenario de interacción humano-robot, el desempeño no depende únicamente de la capacidad del modelo para clasificar ventanas aisladas, sino de la estabilidad con la que esas decisiones se traducen en comandos útiles para el exoesqueleto. En este sentido, la combinación entre clasificación jerárquica, filtrado temporal, máquina de estados y generación suavizada de referencias contribuyó a reducir el impacto de decisiones aisladas o fluctuantes.

La condición con ojos cerrados y pesa grande puede interpretarse como uno de los escenarios más exigentes del protocolo, debido a que combina una mayor demanda mecánica con ausencia de retroalimentación visual. Bajo esta condición, es esperable que se modifiquen los patrones de activación muscular, la postura, la estabilidad del miembro y, potencialmente, la presencia de artefactos en las señales de EEG y sEMG. Por tanto, las variaciones observadas en esta condición no deben interpretarse únicamente como una limitación del clasificador, sino como el reflejo de un escenario experimental más demandante para todo el sistema de adquisición y decisión.

4.3.2. Generalización de sujetos desconocidos

Un aspecto relevante de la metodología fue la comparación entre sujetos conocidos y sujetos desconocidos para el algoritmo. Esta comparación permitió evaluar si el sistema dependía excesivamente de patrones individuales aprendidos durante el entrenamiento o si era capaz de mantener un funcionamiento razonable ante usuarios nuevos. En términos generales, el comportamiento observado sugiere que el sistema no se limitó a memorizar características específicas de los sujetos entrenados, sino que logró capturar información suficientemente general para operar también con participantes no vistos. Sin embargo, las fluctuaciones entre condiciones indican que la generalización todavía puede depender del contexto experimental, de la estabilidad de las señales disponibles y de la similitud entre las condiciones de entrenamiento y prueba.

La condición sin carga representa un caso particularmente interesante, ya que durante la adquisición original para entrenamiento las tareas se realizaron principalmente con carga externa. Al retirar la pesa, cambia la relación entre intención, activación muscular y movimiento esperado, por lo que el patrón multimodal disponible para el clasificador puede diferir del observado durante el entrenamiento. Desde esta perspectiva, las diferencias observadas en dicha condición no necesariamente contradicen la capacidad de generalización del sistema, sino que evidencian la sensibilidad del modelo a cambios en el contexto mecánico de la tarea. En aplicaciones futuras, esto sugiere la conveniencia de incluir una mayor diversidad de condiciones durante el entrenamiento o incorporar estrategias de calibración específicas por usuario y contexto.

4.3.3. Latencia útil, seguridad y estabilidad de control

En cuanto al desempeño temporal, la latencia observada durante la experimentación debe entenderse como una métrica operacional del sistema integrado,

no como el tiempo de cómputo aislado del clasificador. Esta latencia resume el efecto conjunto del ventaneo, el procesamiento, la decisión, la comunicación, la actualización de la máquina de estados y la generación de comandos hacia el controlador. Desde el punto de vista de la interacción humano-robot, esta métrica es especialmente relevante porque determina qué tan rápido una intención detectada puede transformarse en una acción asistiva. Diversas revisiones señalan que una alta complejidad computacional puede comprometer el desempeño en tiempo real, por lo que no basta con reportar precisión si el sistema no puede operar dentro de restricciones temporales compatibles con la interacción física [1, 9].

También es importante aclarar la interpretación temporal del sistema considerando el uso de ventanas deslizantes. Aunque la ventana seleccionada tiene una duración de 1.25 s, el solapamiento del 75 % permite actualizar la decisión aproximadamente cada 312.5 ms. Por esta razón, el retardo efectivo para detectar un cambio de intención no necesariamente equivale a la duración completa de la ventana, sino que depende del punto en que ocurre el cambio dentro del ciclo de actualización, de la evidencia acumulada en ventanas consecutivas y de los criterios de estabilidad usados para confirmar la decisión. Esta interpretación ayuda a explicar por qué pueden observarse diferencias entre eventos sin asumir que el sistema deba esperar siempre una ventana completa para responder.

En este sentido, los ejemplos de latencia presentados en el Capítulo 3 refuerzan que el retardo observado durante la operación *online* no depende únicamente del tiempo de inferencia del modelo, sino también del ventaneo, la estabilidad temporal de la decisión y la forma en que la intención se integra al flujo de control. Este punto es especialmente relevante para sistemas asistivos, donde la respuesta debe ser suficientemente rápida para resultar útil, pero también lo bastante conservadora para evitar cambios erráticos o bruscos en la trayectoria de referencia.

La interpretación de la latencia también debe considerar el tiempo fisiológico

y cognitivo que precede a la respuesta motora. La latencia posterior al cierre de ventana, utilizada como métrica principal en este trabajo, cuantifica únicamente el procesamiento realizado una vez que todas las muestras están disponibles; por tanto, no incluye el intervalo requerido para percibir la indicación auditiva, identificar la clase solicitada, preparar la respuesta y comenzar la activación motora. En tareas auditivas simples se han reportado tiempos de reacción cercanos a 200 ms, aunque estos pueden aumentar cuando la tarea requiere discriminar estímulos, seleccionar entre respuestas y mantener atención sostenida [60, 61]. En consecuencia, una escala próxima a 300 ms resulta plausible para el componente sensoriomotor completo de una tarea como la empleada, pero no debe interpretarse como un valor fijo ni como una magnitud medida directamente en esta tesis.

En el sistema desarrollado, la salida del clasificador se actualizó aproximadamente cada 0.31 s debido al desplazamiento entre ventanas. Esta resolución temporal es del mismo orden que algunos tiempos de reacción humanos, pero representa una propiedad del esquema de segmentación y no la latencia fisiológica del participante. De este modo, el retardo funcional percibido desde la indicación hasta el inicio de la asistencia resulta de la combinación entre procesamiento humano, acumulación de información en la ventana, inferencia del clasificador, filtrado de la máquina de estados y respuesta del exoesqueleto. La latencia computacional de aproximadamente 50–60 ms demuestra que la inferencia posterior al cierre de ventana no constituye el componente dominante, aunque la duración de la ventana y su desplazamiento sí limitan la rapidez con la que un cambio puede incorporarse a una nueva decisión.

4.3.4. Seguimiento de trayectoria y respuesta del exoesqueleto

Un aporte distintivo del trabajo experimental realizado es que no se evaluó únicamente si el sistema clasificaba correctamente, sino también cómo la decisión

se traducía en una referencia de movimiento y en una trayectoria ejecutada por el exoesqueleto. Los ejemplos representativos incluidos en los Apéndices K y L permiten observar esta relación entre intención detectada, referencia generada y posición medida. En segmentos donde el clasificador opera cerca del umbral o presenta alternancias rápidas entre clases, pueden generarse conmutaciones más frecuentes en la referencia discreta; no obstante, la lógica de estabilidad y seguridad atenúa el impacto de decisiones aisladas, favoreciendo transiciones más consistentes hacia trayectorias ejecutables por el actuador.

4.3.5. Comparación con la literatura

La comparación con el estado del arte debe interpretarse con cautela, debido a que los trabajos reportados en la literatura difieren en modalidad de entrada, número de sujetos, tipo de movimiento, duración de ventanas, estrategia de validación y grado de integración con *hardware* robótico. Por ejemplo, algunos estudios reportan exactitudes elevadas en contextos fuera de línea o pseudo-*online*, mientras que otros se enfocan en la integración con dispositivos robóticos específicos o en estrategias avanzadas de fusión multimodal. En consecuencia, las diferencias entre resultados no deben interpretarse únicamente como una comparación directa de precisión, sino considerando el alcance experimental, el tipo de señales utilizadas, la complejidad de la tarea, el esquema de validación y el nivel de integración del sistema.

Para resumir estas diferencias, la Tabla 4.1 presenta una comparación entre trabajos representativos y la propuesta desarrollada en esta tesis. La tabla resalta tanto las métricas principales reportadas por cada estudio como las diferencias metodológicas más relevantes con respecto al presente trabajo.

En comparación con sistemas comerciales de rehabilitación de miembro superior, la contribución de esta tesis se concentra principalmente en la forma de

estimar y traducir la intención del usuario. Plataformas como ArmeoPower y ArmeoSpring están orientadas al entrenamiento terapéutico, al soporte del peso del brazo y al registro del movimiento durante ejercicios funcionales [62, 63], mientras que EksoUE proporciona asistencia mecánica al hombro y al brazo para ampliar el rango activo y la resistencia durante la terapia [64]. Por otra parte, MyoPro constituye una ortesis motorizada de control mioeléctrico, en la cual el movimiento se activa a partir de la señal EMG residual del usuario [65].

Entre los sistemas comerciales revisados no se identificó una integración de EEG, sEMG e IMU para estimar la intención motora y utilizarla como entrada de una arquitectura jerárquica en lazo cerrado. Frente a ello, el aporte del presente trabajo no radica en ofrecer una plataforma comercial terminada, sino en desarrollar y evaluar una arquitectura experimental que combina información cortical, neuromuscular y cinemática, clasificación L1–L2, filtrado temporal mediante una máquina de estados, comunicación con un controlador embebido y generación de movimiento asistido. La inclusión de EEG permite estudiar información relacionada con preparación e intención motora antes o de manera concurrente con la manifestación muscular y cinemática, mientras que sEMG e IMU aportan evidencia complementaria sobre activación y ejecución. No obstante, los sistemas comerciales presentan ventajas en madurez tecnológica, facilidad de uso, soporte clínico, documentación y validación regulatoria que todavía no forman parte del alcance de este prototipo.

Tabla 4.1. Comparación del presente trabajo con estudios relacionados sobre detección de intención motora e interfaces robóticas de asistencia. Continuación.

Trabajo	Señales / sistema	Validación	Resultado principal	Diferencia principal respecto a esta tesis
Li et al. [8]	EEG de imaginación motora + sEMG para HMI de exoesqueleto de miembro inferior.	Evaluación con sujetos usando exoesqueleto; análisis por características y <i>end-to-end</i> .	89.5 % de reconocimiento promedio; 83.6 % <i>cross-subject</i> .	Cercano por integración con exoesqueleto, pero orientado a miembro inferior y asistencia de marcha.
Niu y Jiang [48]	EEG para movimientos distales de miembro superior.	Pseudo- <i>online</i> ; sin actuación robótica.	TPR de 79.6 ± 8.8 %; latencia de 75.3 ± 112.6 ms; clasificación cercana a 67 %.	Evalúa miembro superior, pero usa solo EEG y no cierra el lazo con un exoesqueleto físico.

Continúa en la siguiente página

Tabla 4.1. Comparación del presente trabajo con estudios relacionados sobre detección de intención motora e interfaces robóticas de asistencia. Continuación.

Trabajo	Señales / sistema	Validación	Resultado principal	Diferencia principal respecto a esta tesis
Zou et al. [9]	EMG + EEG para exoesqueleto de mano con control por admitancia.	Control en tiempo real de exoesqueleto de mano.	NRMSE de seguimiento articular de aproximadamente 6.46–10.94 %; ICJT promedio de 73.18 %.	Se centra en admitancia y participación del usuario, no en clasificación jerárquica de intención ni variabilidad entre sujetos.
BenAbdallah et al. [66]	EMG + EEG para robot de rehabilitación de codo.	Interfaz híbrida en robot de rehabilitación.	94.5 % de exactitud; latencia <i>end-to-end</i> menor a 500 ms.	Muy cercano por codo y fusión EEG–EMG, pero no incorpora IMU ni condiciones de visión/carga con sujetos conocidos y desconocidos.
Obukhov et al. [50]	EMG + IMU + VR para clasificación de actividades de miembro superior.	Estudio multisensorial orientado a control de exoesqueleto y VR.	Hasta 99.2 % con Transformer usando todas las señales.	Alta exactitud multisensorial, pero sin EEG ni validación fisiológica cortical de intención.

Continúa en la siguiente página

Tabla 4.1. Comparación del presente trabajo con estudios relacionados sobre detección de intención motora e interfaces robóticas de asistencia. Continuación.

Trabajo	Señales / sistema	Validación	Resultado principal	Diferencia principal respecto a esta tesis
Sultan et al. [67]	EEG + EMG con Transformer para gestos de miembro superior.	Evaluación sobre <i>datasets</i> con adaptación <i>online</i> .	97 % y 96 % de exactitud en dos <i>datasets</i> .	Modelo avanzado de fusión, pero sin validación física directa con exoesqueleto en el estudio reportado.
Esta tesis	EEG + sEMG + IMU para intención motora de miembro superior derecho.	Validación <i>online</i> en lazo cerrado con exoesqueleto, cRIO, UDP, máquina de estados y cuatro condiciones de visión/carga.	Precisión: 82.78–88.50 %; sensibilidad: 77.78–85.94 %; latencia post-ventana: 49.60–59.94 ms.	Integra señales corticales, musculares y cinemáticas con un exoesqueleto físico, evaluando sujetos conocidos/desconocidos, variabilidad de condición y latencia del sistema integrado.

Nota. EEG: electroencefalografía; sEMG: electromiografía de superficie; IMU: unidad de medición inercial; HMI: interfaz humano-máquina; cRIO: controlador CompactRIO; UDP: protocolo de datagramas de usuario; TPR: tasa de verdaderos positivos; NRMSE: raíz del error cuadrático medio normalizado; ICJT: inconsistencias entre la concentración y el torque articular; VR: realidad virtual.

Como se observa en la Tabla 4.1, varios trabajos reportan desempeños superiores en términos de exactitud o precisión; sin embargo, dichos resultados suelen provenir de tareas fuera de línea, bases de datos específicas, movimientos de miembro inferior, esquemas pseudo-*online* o sistemas que no cierran completamente el lazo con un exoesqueleto físico. En contraste, esta tesis priorizó la integración completa del flujo HMI-exoesqueleto, incluyendo adquisición multimodal, procesamiento, clasificación jerárquica, comunicación con el sistema embebido, máquina de estados, generación de referencias y validación experimental en tiempo real.

Bajo este enfoque, las métricas más bajas observadas en algunas condiciones pueden entenderse como una consecuencia directa de las prioridades metodológicas del presente estudio. A diferencia de trabajos que se concentran principalmente en optimizar la clasificación fuera de línea, esta tesis evaluó el sistema bajo variabilidad entre sujetos conocidos y desconocidos, incorporó variaciones experimentales deliberadas de visión y carga, y utilizó una configuración orientada a la operación *online* dentro de una arquitectura HMI-exoesqueleto. Estas decisiones hacen más exigente el problema y pueden limitar la precisión máxima alcanzable por condición, pero aportan una evaluación más cercana a un escenario de uso real.

En conjunto, la comparación muestra que la principal contribución de esta tesis no radica únicamente en alcanzar el mayor valor de clasificación, sino en demostrar la factibilidad de una arquitectura integrada para detección de intención motora y asistencia robótica en tiempo real. El desempeño final debe entenderse como el resultado de la interacción entre señales fisiológicas y cinemáticas, modelo de clasificación, reglas temporales, comunicación embebida y control del exoesqueleto. Por ello, más que interpretar el sistema como un clasificador aislado, el presente trabajo lo plantea como una plataforma completa de decisión y asistencia para interacción HMI-exoesqueleto.

4.4. Alcances estadísticos de los hallazgos

El análisis estadístico permitió complementar la interpretación descriptiva de los resultados experimentales y evaluar si las variaciones observadas podían atribuirse de manera consistente a la condición experimental, al grupo de generalización o a la interacción entre ambos factores.

4.4.1. Tendencias descriptivas y variabilidad intersujeto

En términos generales, los modelos mixtos no mostraron evidencia estadística suficiente para afirmar que el desempeño del sistema cambiara de forma sistemática entre sujetos conocidos y desconocidos. Este resultado es relevante porque sugiere que la arquitectura de clasificación no dependió exclusivamente de patrones individuales aprendidos durante el entrenamiento. Sin embargo, esta interpretación debe mantenerse con cautela, ya que la ausencia de significancia estadística no demuestra equivalencia completa entre grupos, sino que indica que, bajo el tamaño muestral y las condiciones evaluadas, no se detectaron diferencias consistentes atribuibles al nivel de generalización.

La condición experimental tampoco mostró un efecto sistemático robusto sobre todas las métricas. Aunque algunas condiciones tendieron a presentar menor desempeño o mayor variabilidad, especialmente aquellas asociadas con mayor demanda mecánica o cambios en el contexto de ejecución, estas diferencias no se mantuvieron de forma consistente después de considerar la variabilidad entre sujetos y la corrección por comparaciones múltiples. Esto refuerza la idea de que el comportamiento del sistema estuvo influido por una combinación de factores: la calidad de las señales, la estabilidad de la ejecución, las diferencias individuales y la condición experimental, más que por un único factor dominante.

Parte de esta variabilidad también pudo relacionarse con procesos cognitivos no cuantificados durante las sesiones. Factores como la atención, la motivación,

el estrés, la carga mental y la fatiga pueden modificar la actividad espectral del EEG y la consistencia del desempeño durante tareas motoras [68, 69]. En este contexto, una disminución de la atención o un aumento de la fatiga a lo largo de los bloques podría reducir la estabilidad de las características sensoriomotoras y aumentar la variabilidad entre ventanas. Asimismo, una mayor demanda cognitiva podría influir en la comprensión de las indicaciones, el tiempo de respuesta, la imaginación motora y la ejecución muscular, afectando de forma indirecta la clasificación multimodal.

4.4.2. Efectos sistemáticos y ausencia de diferencias robustas

La inclusión de un intercepto aleatorio por sujeto fue importante porque las mediciones de un mismo participante no son independientes entre sí. En este sentido, los modelos mixtos permitieron separar parcialmente la variabilidad individual de los efectos asociados al protocolo. El hecho de que parte de la variabilidad, especialmente en latencia, pueda atribuirse a diferencias entre sujetos es coherente con la naturaleza del sistema, ya que cada usuario puede presentar patrones distintos de activación muscular, estabilidad postural, respuesta a la carga, calidad de señal y consistencia durante la ejecución de las tareas.

Las comparaciones *post-hoc* apoyan esta misma interpretación. Aunque se observaron algunas tendencias entre condiciones o entre grupos, estas no permanecieron significativas después del ajuste por comparaciones múltiples. Desde el punto de vista práctico, esto sugiere que las diferencias observadas en las métricas deben interpretarse como variaciones esperables dentro de un sistema multimodal *online*, más que como efectos concluyentes de una condición específica. Por esto, los resultados respaldan una estabilidad general del sistema, pero no permiten afirmar que todas las condiciones sean equivalentes ni que el desempeño sea completamente independiente del contexto experimental.

4.4.3. Relación entre precisión y latencia

En cuanto a la relación entre precisión y latencia, el análisis no mostró evidencia de un compromiso estadístico claro entre ambas variables dentro del rango observado. Esto sugiere que, en la configuración evaluada, las variaciones moderadas en el tiempo de respuesta no se asociaron con mejoras o deterioros consistentes en la precisión. Esta observación es coherente con la arquitectura del sistema, ya que la latencia operacional depende en gran medida del ventaneo, el procesamiento, la estabilización temporal y la actualización del comando, mientras que la precisión depende principalmente de la separabilidad entre clases, la calidad de las señales y la consistencia de la ejecución.

No obstante, esta ausencia de relación detectable entre precisión y latencia debe interpretarse dentro de los límites del estudio. El número de sujetos y bloques por condición fue suficiente para una evaluación inicial del sistema, pero todavía limitado para detectar efectos pequeños o compromisos sutiles entre desempeño y respuesta temporal. En este contexto, los “efectos pequeños” corresponden a variaciones cuyo impacto queda por debajo de la resolución estadística y funcional del sistema evaluado. Desde el punto de vista estadístico, las diferencias observadas entre condiciones fueron de magnitud reducida y no permanecieron significativas después de la corrección por comparaciones múltiples, por lo que no pueden atribuirse de forma concluyente a una condición experimental específica. Desde el punto de vista funcional, el sistema tampoco opera mediante un umbral directo sobre una señal cruda o el valor de una característica base. En su lugar, cada decisión se obtiene a partir de una ventana multimodal de análisis, en la que se integran características corticales, neuromusculares y cinemáticas.

Bajo esta arquitectura, la unidad mínima de observación funcional está dada por la ventana de análisis. En la implementación utilizada, cada decisión se calculó con ventanas de 1.25 s y un desplazamiento aproximado de 0.31 s, por lo que la

salida del clasificador se actualizó a una escala cercana a 300 ms. Por tanto, una variación breve, como una contracción muscular involuntaria, una distracción durante la tarea o un cambio postural pequeño, tendría impacto en el sistema solo si modifica suficientemente el contenido de una ventana para alterar el vector de características EEG-sEMG-IMU y cambiar la salida jerárquica L1-L2. En otras palabras, el efecto no se evalúa como una fluctuación instantánea de señal, sino como un cambio integrado dentro de una ventana temporal.

Además, una etiqueta de intención modificada en una ventana no necesariamente se traduce de forma inmediata en movimiento del exoesqueleto. La salida del clasificador se envía al cRIO como intención cruda y posteriormente pasa por la máquina de estados, la cual actúa como un filtro temporal y de seguridad. Por ello, una decisión aislada o transitoria puede ser absorbida por las reglas de estabilidad, mientras que una intención sostenida en ventanas consecutivas tiene mayor probabilidad de modificar el estado funcional del sistema. Así, el valor cercano a 300 ms no representa un umbral fisiológico mínimo, sino la resolución temporal práctica con la que una perturbación puede empezar a reflejarse en la clasificación; su traducción a movimiento depende de la consistencia de la intención y de las reglas temporales de la máquina de estados.

Por ejemplo, una activación muscular breve o un movimiento involuntario del brazo podría modificar parcialmente características como RMS, MAV o la magnitud de la IMU. Sin embargo, si dicha alteración no es suficiente para cambiar la clasificación L1-L2, o si aparece solo en una ventana aislada, no necesariamente provocará una transición funcional del exoesqueleto. En cambio, una activación más sostenida y coherente entre modalidades tendría mayor probabilidad de modificar la intención estimada y superar el filtrado temporal del sistema. En consecuencia, en este trabajo no se caracterizó un desplazamiento angular mínimo detectable del usuario; la resolución evaluada fue temporal y funcional, determina-

da por la integración de información en ventanas actualizadas aproximadamente cada 0.31 s, y por su posterior filtrado mediante la máquina de estados.

En trabajos futuros, una muestra mayor, más sesiones por participante y condiciones de prueba más diversas podrían aumentar la sensibilidad estadística y permitir una caracterización más precisa de los factores que modulan la generalización, la estabilidad temporal y el desempeño del sistema.

En conjunto, el análisis estadístico respalda que el sistema mantuvo un comportamiento comparable entre grupos y condiciones dentro del protocolo evaluado. Más que demostrar una generalización definitiva, estos resultados deben entenderse como evidencia inicial de viabilidad: el sistema fue capaz de operar en tiempo real con sujetos conocidos y desconocidos, sin que las variaciones observadas se tradujeran en efectos estadísticos robustos bajo el diseño experimental empleado. Esto refuerza la pertinencia de continuar con evaluaciones más amplias que permitan confirmar la estabilidad del enfoque multimodal y su capacidad de adaptación a usuarios y contextos más diversos.

05

Conclusiones

En este Capítulo se presentan las conclusiones generales derivadas del desarrollo y la evaluación de este trabajo, integrando los principales hallazgos teóricos, metodológicos y experimentales. Asimismo, se discuten las implicaciones de los resultados obtenidos, sus alcances y limitaciones, así como posibles líneas de trabajo futuro. A continuación, se enumeran las conclusiones más relevantes que resumen las aportaciones de esta investigación.

5.1. Conclusiones generales

En esta tesis se logró desarrollar, integrar y evaluar un sistema de detección de intenciones de movimiento articular del usuario para robots de asistencia, combinando información bioeléctrica y cinemática dentro de un flujo completo de adquisición, procesamiento, clasificación e integración con una plataforma experimental. La implementación permitió avanzar desde una evaluación *offline* hasta una operación en tiempo real, incorporando escenarios representativos de condiciones reales de uso. En este proceso, la integración multimodal mostró ser una estrategia útil para aportar estabilidad ante variaciones propias de las sesiones experimentales, fortaleciendo la viabilidad del sistema más allá de escenarios estrictamente controlados.

El diseño y ejecución del protocolo experimental confirmó que la adquisición estandarizada de señales en seres humanos representa un reto técnico relevante. La necesidad de controlar fases, tiempos, retroalimentación, condiciones de carga, instrucciones al participante y criterios de registro evidenció que el desempeño del sistema no depende únicamente del modelo de clasificación, sino también de la calidad y reproducibilidad del protocolo. A partir de las pruebas realizadas, se identificó la conveniencia de precisar en futuros estudios requisitos funcionales asociados a movilidad reducida, más allá de criterios generales de edad o estado de salud, con el fin de aumentar la seguridad, comparabilidad y reproducibilidad

de las adquisiciones.

En cuanto al modelo de detección, el enfoque jerárquico L1–L2 basado en máquinas de soporte vectorial mostró un desempeño consistente y compatible con la operación *online*. Esta arquitectura permitió separar la detección de movimiento frente a reposo de la discriminación entre flexión y extensión, reduciendo la complejidad de cada subproblema y favoreciendo un balance adecuado entre precisión, sensibilidad y costo computacional. Aunque modelos más complejos podrían alcanzar métricas superiores en condiciones controladas, los resultados del sistema completo indican que un clasificador simple, bien calibrado y eficiente puede ser una alternativa práctica cuando la latencia, la estabilidad temporal y la generalización son restricciones centrales.

Los resultados del proceso de optimización también sugieren que maximizar una sola métrica hasta valores extremos no necesariamente conduce a la mejor solución para un sistema de asistencia en tiempo real. En este tipo de aplicaciones, una configuración útil debe mantener un desempeño adecuado en precisión y sensibilidad, pero también conservar la consistencia temporal de las decisiones y la viabilidad computacional del flujo completo. Por ello, la selección final del modelo y de los parámetros de segmentación debe entenderse como un compromiso entre rendimiento, estabilidad y posibilidad de implementación en una arquitectura operativa.

La transferencia del procesamiento de señales hacia una plataforma experimental con exoesqueleto evidenció que la implementación en condiciones reales introduce retos adicionales que no aparecen en validaciones exclusivamente *offline*. La instrumentación del usuario, la sincronización entre dispositivos, el registro temporal, la comunicación con el controlador embebido, la generación de referencias y la evaluación de latencias consolidaron el proyecto como un sistema biomédico integrado, no únicamente como un clasificador aislado. En este sentido, el

trabajo refuerza el carácter aplicado de la Ingeniería Biomédica y la Bioingeniería, al conectar procesamiento de señales, inteligencia artificial, control y robótica de asistencia en un mismo flujo experimental.

Finalmente, el desarrollo de la interfaz humano-máquina y la estructura de fases e instrucciones fueron elementos esenciales para controlar el experimento, disminuir la ambigüedad en la interpretación de la intención y facilitar la replicabilidad del protocolo. Esta HMI no solo permitió organizar la adquisición y operación del sistema, sino que también abre líneas claras de continuidad, como la calibración guiada, la adaptación progresiva al usuario y la incorporación de estrategias de retroalimentación multimodal para mejorar la aceptación, estabilidad y desempeño del sistema en escenarios futuros de asistencia.

5.2. Contribuciones técnicas

A partir de este proyecto de tesis se obtuvo un sistema multimodal integrado para la adquisición, sincronización, procesamiento y análisis de señales de EEG, sEMG e IMU. Esta integración permitió construir un flujo de trabajo estructurado desde el registro de señales hasta la generación de vectores de características listos para entrenamiento, validación e inferencia. De esta forma, una de las principales contribuciones técnicas fue la consolidación de una arquitectura funcional capaz de organizar información bioeléctrica y cinemática proveniente de distintos dispositivos, manteniendo una sincronización práctica entre modalidades y una estructura de datos reproducible para análisis posteriores.

Otra contribución importante fue la generación de una base de datos experimental propia, adquirida bajo un protocolo definido por fases, bloques de movimiento y condiciones de registro. Aunque el desarrollo final de esta tesis se centró en la flexión y extensión de hombro, el protocolo permitió adquirir información asociada a tres grados de libertad del miembro superior derecho. Esto deja una

base útil para futuras extensiones del sistema hacia movimientos adicionales, así como para estudios posteriores relacionados con generalización, selección de características y evaluación de modelos de detección de intención motora.

Desde el punto de vista computacional, se desarrolló una estructura de clasificación jerárquica con etapas claras de segmentación, extracción de características, reducción de redundancias, entrenamiento, validación e inferencia en tiempo real. Esta arquitectura permitió separar la detección de movimiento frente a reposo de la discriminación entre flexión y extensión, favoreciendo un flujo de decisión más interpretable y compatible con restricciones de operación *online*. Además, se implementaron herramientas de optimización y evaluación que permitieron comparar configuraciones de segmentación, bloques de características, parámetros del clasificador y esquemas de validación, las cuales pueden ser reutilizadas o ampliadas en trabajos futuros.

Una contribución adicional fue la integración del sistema de clasificación con una plataforma experimental de exoesqueleto, incorporando elementos de HMI, comunicación con el controlador embebido, monitoreo de variables temporales, máquina de estados, generación de referencias y operación del robot. Esta integración permitió que el trabajo no se limitara a un análisis *offline* de clasificadores, sino que avanzara hacia una validación experimental del flujo completo entre intención detectada y movimiento asistido. En este sentido, la infraestructura desarrollada constituye una base técnica para futuras pruebas de calibración, adaptación al usuario y control asistivo en escenarios más cercanos al uso real.

Finalmente, parte de los resultados técnicos derivados de esta tesis fueron presentados en el Congreso Nacional de Ingeniería Biomédica (CNIB) 2025 [59], particularmente aquellos relacionados con la optimización del sistema de clasificación y la selección de configuraciones para el procesamiento multimodal. En conjunto, estas contribuciones respaldan la factibilidad de implementar la detec-

ción multimodal de intenciones de movimiento en un sistema de asistencia operado en tiempo real, destacando que el valor del trabajo radica tanto en el desempeño de la clasificación como en la ingeniería necesaria para integrar adquisición, procesamiento, interacción humano-robot y evaluación temporal bajo condiciones experimentales realistas.

5.3. Limitaciones, casos límite y trabajo futuro

A pesar de que los resultados obtenidos respaldan la viabilidad del sistema en operación *online* y en lazo cerrado, esta tesis presenta limitaciones metodológicas y técnicas que deben considerarse para delimitar el alcance de los hallazgos y orientar mejoras futuras.

5.3.1. Limitaciones del estudio

En primer lugar, una limitación relevante es el número de canales de EEG disponibles. El uso de un registro de baja densidad restringe la cantidad de información espacial accesible y puede limitar tanto la separabilidad entre clases como la robustez frente a variabilidad inter e intra-sujeto. En consecuencia aunque el desempeño alcanzado fue consistente, es posible que una configuración con mayor cobertura cortical o estrategias de selección y optimización espacial más amplias permita reducir errores residuales y mejorar la generalización, especialmente en sujetos nuevos.

En segundo lugar, una parte crítica del desarrollo estuvo condicionada por la arquitectura multimodal de adquisición y por los retos prácticos de sincronización entre dispositivos. En un sistema *online*, pequeñas discrepancias temporales entre flujos de datos pueden introducir inconsistencias en la construcción de ventanas y en el etiquetado funcional de eventos, afectando indirectamente la clasificación y la medición de latencia. Aunque se implementaron mecanismos para mantener

coherencia operativa, una línea inmediata de mejora es fortalecer la sincronización mediante marcas de tiempo unificadas, disparos por *hardware* de ser posible y validaciones sistemáticas del desfase residual en distintos escenarios de operación.

Otra limitación importante se relaciona con la formalización del protocolo para población con movilidad reducida. Si bien se establecieron criterios generales como la edad y las condiciones principales de salud, en un escenario clínico sería preferible especificar con mayor claridad los requisitos físicos funcionales, como los rangos mínimos de movimiento, capacidad de mantener posturas, tolerancia a carga, fatiga, espasticidad, dolor o temblor, y los criterios de exclusión e inclusión asociados a la ejecución segura y repetible de las tareas. Esto permitiría reducir una heterogeneidad no controlada, así como mejorar la comparabilidad entre participantes y facilitar la transición hacia estudios con usuarios objetivo.

Asimismo, el estado cognitivo de los participantes no se cuantificó de forma directa. Aunque el protocolo empleó instrucciones estandarizadas, indicaciones auditivas, periodos de descanso y criterios relacionados con sueño, fatiga e incomodidad, no se utilizaron escalas subjetivas ni medidas fisiológicas específicas para separar los efectos de la atención, la motivación, el estrés, la carga mental o la fatiga de la variabilidad propia de las señales. Por ello, una parte de la variabilidad inter- e intra-sujeto observada podría estar asociada con cambios en el estado cognitivo de los participantes.

Aunque se efectuó una auditoría *offline* de consistencia utilizando información de sEMG e IMU, no se dispuso de video, goniometría ni captura de movimiento como referencia externa independiente. Por esto, fue posible identificar ventanas potencialmente inconsistentes, pero no reconstruir con certeza la trayectoria ejecutada voluntariamente por el participante en todos los ensayos.

Desde el punto de vista ingenieril, el trabajo también estuvo limitado por la gestión del *software* durante el proceso iterativo, todo esto referente al uso de

múltiples versiones de códigos, ajustes de parámetros, cambios de configuraciones y optimizaciones realizadas con los recursos disponibles en el laboratorio. Aunque esto es común en desarrollos aplicados, como trabajo a futuro se plantea consolidar el proyecto bajo prácticas de reproducibilidad más estrictas, como el control de versiones más formal, una documentación de configuraciones, archivos de parámetros por experimento, entornos de desarrollo y pruebas automatizadas orientadas a la reducción de regresiones durante la modificación de módulos.

La latencia constituye otra limitación, y al mismo tiempo, una oportunidad de mejora. En las etapas iniciales se enfrentaron dificultades para reducir latencias asociadas al procesamiento y a la comunicación e implementación en el cRIO, y se realizaron exploraciones con diferentes tamaños de ventana hasta llegar a la configuración final. Si bien, las ventanas empleadas representan un compromiso adecuado para este sistema y estos sensores, es razonable suponer que existen configuraciones aún más eficientes. En específico, el proceso de optimización se podría enfocar en: reducir el costo computacional por ventana, aplicar decisiones tempranas, así como estrategias de confirmación más rápidas, evaluar las tasas de actualización mayores y rediseñar el esquema de adquisición y procesamiento para minimizar cuellos de botella.

5.3.2. Casos límite y fallos observables

Durante la implementación y las pruebas *online* se identificaron distintos escenarios capaces de degradar el desempeño del sistema o inducir eventos no deseados. Estos casos límite no necesariamente representan fallos aislados del clasificador, sino condiciones propias de la adquisición multimodal, la variabilidad humana y la operación mediante ventanas deslizantes.

Uno de los factores más sensibles fue la variabilidad en la colocación de los electrodos, especialmente en las señales de sEMG, ya que pequeños cambios en

la posición o en el contacto pueden modificar la amplitud y la forma de la señal registrada. De manera similar, la señal de EEG puede verse afectada por artefactos no neuronales, como parpadeos, tensión facial, masticación o habla, los cuales introducen actividad que puede confundirse con cambios asociados a la tarea motora. En el caso de la EMG, también pueden aparecer microcontracciones o co-contracciones involuntarias, generando ventanas con activación muscular que no corresponden necesariamente a una intención clara de movimiento.

Otro caso límite corresponde al desfase residual entre modalidades. Aunque la arquitectura implementada permitió una sincronización funcional entre señales, pequeños desfases de decenas de milisegundos pueden provocar que una misma ventana contenga información de fases diferentes del protocolo. Esto es especialmente relevante durante las transiciones entre reposo, ejecución y mantenimiento, donde la decisión del clasificador puede depender del instante exacto en que cae la ventana. Por ello, una predicción aparentemente incorrecta en una zona de transición no siempre debe interpretarse como un error del modelo, sino también como una consecuencia del muestreo temporal mediante ventanas deslizantes.

También se observó que la fatiga y la variación temporal del patrón motor pueden modificar la forma en que el usuario ejecuta la tarea a lo largo de los bloques. Con el avance de la sesión, los participantes pueden reducir la amplitud del movimiento, aumentar la tensión muscular, realizar pausas irregulares o modificar su estrategia de ejecución. Estos cambios pueden disminuir el desempeño si no están suficientemente representados en los datos de entrenamiento o si el sistema no incorpora mecanismos de adaptación. De forma adicional, activaciones breves no intencionadas, como ajustes de postura, acomodo del brazo o temblores, pueden generar ventanas con actividad muscular o cinemática suficiente para producir decisiones transitorias.

En conjunto, estos casos límite muestran que el desempeño del sistema no

depende únicamente del algoritmo de clasificación, sino también de la estabilidad de la instrumentación, la calidad de las señales, la sincronización entre modalidades y la consistencia del usuario durante la tarea. Por ello, futuras versiones del sistema deberán contemplar estrategias de calibración más robustas, detección de artefactos, adaptación temporal y reglas de confirmación que permitan diferenciar mejor entre intención sostenida, transiciones normales del protocolo y activaciones espurias.

5.3.3. Trabajo futuro

En cuanto a la proyección a futuro, se identificaron dos rutas complementarias. La primera consiste en profundizar en la contribución relativa del EEG dentro del esquema multimodal, con el objetivo de evaluar escenarios donde el sistema dependa principalmente de la información cortical. Aunque el modelo final utilizó una fusión normalizada sin ponderación diferenciada entre modalidades, una extensión relevante sería incorporar pesos adaptativos según el usuario, la sesión y la calidad instantánea de cada señal. Esto permitiría ajustar dinámicamente la contribución de EEG, sEMG e IMU, caracterizar con mayor precisión sus límites de generalización y sensibilidad ante artefactos, y evaluar el desempeño del sistema en escenarios de operación real con activación muscular limitada o ausente. La segunda ruta apunta a incrementar la complejidad funcional del control. Más allá de intenciones de movimiento simple de una sola articulación o de acciones discretas, un trabajo futuro relevante es extender el enfoque hacia múltiples grados de libertad y hacia la detección de tareas o intenciones compuestas, lo cual acercaría el sistema a escenarios de rehabilitación más complejos y a interacciones humano-robot de mayor nivel.

Como extensión futura en el contexto de mejora los tiempos de respuesta del sistema, podría explorarse una estrategia de fusión temporal adaptativa que

aproveche la disponibilidad secuencial de las modalidades: el EEG como evidencia anticipatoria de preparación motora, la sEMG como confirmación de activación neuromuscular y la IMU como verificación de la ejecución y dirección del movimiento. Una arquitectura de decisión temprana permitiría emitir o preparar una respuesta con la primera evidencia confiable y reforzarla posteriormente con las modalidades restantes, evitando exigir en todos los casos la misma cantidad de información y reduciendo potencialmente el retardo funcional sin comprometer la seguridad.

En general, esta tesis permitió validar una arquitectura funcional en operación *online* y con integración robótica. Sin embargo, también se identificaron áreas de mejora tales como: aumentar la densidad informativa, robustecer la sincronización multimodal, formalizar criterios funcionales para usuarios con movilidad reducida, fortalecer la reproducibilidad del *software* y optimizar la respuesta temporal con estrategias que reduzcan latencias sin comprometer el desempeño.

Referencias

- [1] J. Yang, Y. He, P. Shi, and H. Yu, “A review on human intent understanding and compliance control strategies for lower limb exoskeletons,” *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, vol. 236, no. 6, pp. 1067–1086, Jul. 2022, publisher: IMECHE. [Online]. Available: <https://doi.org/10.1177/09596518221085793>
- [2] S. Luo, Q. Meng, S. Li, and H. Yu, “Research of intent recognition in rehabilitation robots: a systematic review,” *Disability and Rehabilitation. Assistive Technology*, vol. 19, no. 4, pp. 1307–1318, May 2024.
- [3] D. Su, Z. Hu, J. Wu, P. Shang, and Z. Luo, “Review of adaptive control for stroke lower limb exoskeleton rehabilitation robot based on motion intention recognition,” *Frontiers in Neurorobotics*, vol. 17, p. 1186175, 2023.
- [4] S. Duan, C. Wang, M. Li, Z. Su, J. Liu, and X. Wu, “A Framework for Human-Exoskeleton Interaction Based on sEMG Interface and Electrotactile Feedback,” in *2021 IEEE International Conference on Real-time Computing and Robotics (RCAR)*, Jul. 2021, pp. 269–274. [Online]. Available: <https://ieeexplore.ieee.org/document/9517365>
- [5] Y. Long, Z.-j. Du, W.-d. Wang, and W. Dong, “Human motion intent learning based motion assistance control for a wearable exoskeleton,” *Robotics and Computer-Integrated Manufacturing*, vol. 49, pp. 317–327, Feb. 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0736584516301740>
- [6] D. Wang, X. Gu, and H. Yu, “Sensors and algorithms for locomotion intention detection of lower limb exoskeletons,” *Medical Engineering & Physics*, vol. 113, p. 103960, Mar. 2023.
- [7] V. I. Ramírez-Vera, M. O. Mendoza-Gutiérrez, and I. Bonilla-Gutiérrez, “Impedance Control with Bounded Actions for Human–Robot Interaction,” *Arabian Journal for Science and Engineering*, vol. 47, no. 11, pp. 14 989–15 000, Nov. 2022. [Online]. Available: <https://doi.org/10.1007/s13369-022-06638-3>
- [8] W. Li, Y. Ma, K. Shao, Z. Yi, W. Cao, M. Yin, T. Xu, and X. Wu, “The Human–Machine Interface Design Based on sEMG and Motor Imagery EEG for Lower Limb Exoskeleton

- Assistance System,” *IEEE Transactions on Instrumentation and Measurement*, vol. 73, pp. 1–14, 2024. [Online]. Available: <https://ieeexplore.ieee.org/document/10479169>
- [9] H. Zou, Q. Wu, L. Yang, Y. Zhu, and H. Wu, “Design and EMG-EEG Fusion-Based Admittance Control of a Hand Exoskeleton With Series Elastic Actuators,” *IEEE Transactions on Medical Robotics and Bionics*, vol. 7, no. 1, pp. 347–358, Feb. 2025. [Online]. Available: <https://ieeexplore.ieee.org/document/10759806>
- [10] M. S. Al-Quraishi, I. Elamvazuthi, T. B. Tang, M. Al-Qurishi, S. Parasuraman, and A. Borboni, “Multimodal Fusion Approach Based on EEG and EMG Signals for Lower Limb Movement Recognition,” *IEEE Sensors Journal*, vol. 21, no. 24, pp. 27 640–27 650, Dec. 2021. [Online]. Available: <https://ieeexplore.ieee.org/document/9565878>
- [11] B. Sun, G. Cheng, Q. Dai, T. Chen, W. Liu, and X. Xu, “Human motion intention recognition based on EMG signal and angle signal,” *Cognitive Computation and Systems*, vol. 3, no. 1, pp. 37–47, 2021, _eprint: <https://ietresearch.onlinelibrary.wiley.com/doi/pdf/10.1049/ccs2.12002>. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1049/ccs2.12002>
- [12] Z. Lei, “An upper limb movement estimation from electromyography by using BP neural network,” *Biomedical Signal Processing and Control*, vol. 49, pp. 434–439, Mar. 2019. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1746809418303197>
- [13] A. C. Villa-Parra, D. Delisle-Rodriguez, T. Botelho, J. J. V. Mayor, A. L. Delis, R. Carelli, A. Frizera Neto, and T. F. Bastos, “Control of a robotic knee exoskeleton for assistance and rehabilitation based on motion intention from sEMG,” *Research on Biomedical Engineering*, vol. 34, pp. 198–210, Jul. 2018, publisher: Sociedade Brasileira de Engenharia Biomédica. [Online]. Available: <https://www.scielo.br/j/reng/a/r9BHBHm9yHsRXg4sRcNBRXK/?lang=en>
- [14] B. Blankertz, G. Dornhege, M. Krauledat, K.-R. Müller, and G. Curio, “The non-invasive Berlin Brain-Computer Interface: fast acquisition of effective performance in untrained subjects,” *NeuroImage*, vol. 37, no. 2, pp. 539–550, Aug. 2007.
- [15] Z. Feng, Y. Sun, L. Qian, Y. Qi, Y. Wang, C. Guan, and Y. Sun, “Design a Novel BCI for Neurorehabilitation Using Concurrent LFP and EEG Features: A Case Study,” *IEEE transactions on bio-medical engineering*, vol. 69, no. 5, pp. 1554–1563, May 2022.

- [16] M. Lassi, A. Bandini, V. Spina, V. Azzollini, S. Dalise, A. Mazzoni, C. Chisari, and S. Micera, "Classification of upper limb impairment in acute stroke patients using resting-state EEG markers and machine learning," in *2023 11th International IEEE/EMBS Conference on Neural Engineering (NER)*, Apr. 2023, pp. 1–4, iSSN: 1948-3554. [Online]. Available: <https://ieeexplore.ieee.org/document/10123720>
- [17] N. Hooda, R. Das, and N. Kumar, "Fusion of EEG and EMG signals for classification of unilateral foot movements," *Biomedical Signal Processing and Control*, vol. 60, p. 101990, Jul. 2020. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1746809420301464>
- [18] S. M. S. Hasan, M. R. Siddiquee, and O. Bai, "Asynchronous Prediction of Human Gait Intention in a Pseudo Online Paradigm Using Wavelet Transform," *IEEE transactions on neural systems and rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society*, vol. 28, no. 7, pp. 1623–1635, Jul. 2020.
- [19] T. Callens, V. Ducastel, J. D. Schutter, and E. Aertbeliën, "Using Intent Estimation and Decision Theory to Support Lifting Motions with a Quasi-Passive Hip Exoskeleton," Apr. 2023, arXiv:2304.12649 [cs]. [Online]. Available: <http://arxiv.org/abs/2304.12649>
- [20] V. Mishuhina and X. Jiang, "Complex common spatial patterns on time-frequency decomposed EEG for brain-computer interface," *Pattern Recognition*, vol. 115, p. 107918, Jul. 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S003120321001059>
- [21] B. Hu, E. Rouse, and L. Hargrove, "Fusion of Bilateral Lower-Limb Neuromechanical Signals Improves Prediction of Locomotor Activities," *Frontiers in robotics and AI*, vol. 5, p. 78, 2018.
- [22] A. Jafarifarmand, M.-A. Badamchizadeh, S. Khanmohammadi, M. A. Nazari, and B. M. Tazehkand, "Real-time ocular artifacts removal of EEG data using a hybrid ICA-ANC approach," *Biomedical Signal Processing and Control*, vol. 31, pp. 199–210, Jan. 2017. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1746809416301070>
- [23] D. Yadav and K. Veer, "Recent trends and challenges of surface electromyography in prosthetic applications," *Biomedical Engineering Letters*, vol. 13, no. 3, pp. 353–373, Apr. 2023. [Online]. Available: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10382439/>

- [24] P. U. Broniera Junior, D. P. Campos, A. E. Lazzaretti, P. Nohama, A. A. U. Carvalho, E. Krueger, and M. C. U. Minhoto Teixeira, “EEG-FES-Force-MMG closed-loop control systems of a volunteer with paraplegia considering motor imagery with fatigue recognition and automatic shut-off,” Jul. 2021. [Online]. Available: <http://hdl.handle.net/11449/206252>
- [25] S. Lamas, “Systematic review of the use of robots for upper limb rehabilitation after stroke,” Ph.D. dissertation, Universidade da Coruña, Sep. 2015. [Online]. Available: <https://ruc.udc.es/items/c5193362-4d64-419d-9571-544d765ce9eb>
- [26] N. Rehmat, J. Zuo, W. Meng, Q. Liu, S. Q. Xie, and H. Liang, “Upper limb rehabilitation using robotic exoskeleton systems: a systematic review,” *International Journal of Intelligent Robotics and Applications*, vol. 2, no. 3, pp. 283–295, Sep. 2018. [Online]. Available: <https://doi.org/10.1007/s41315-018-0064-8>
- [27] D. S. Méndez, M. A. Montiel, and E. L. González, “Diseño de un Prototipo de Exoesqueleto para Rehabilitación del Hombro,” *Revista Mexicana de Ingeniería Biomedica*, vol. 38, no. 1, pp. 330–342, Jan. 2017. [Online]. Available: <https://www.rmib.mx/index.php/rmib/article/view/37>
- [28] V. L. Feigin, M. Brainin, B. Norrving, S. O. Martins, J. Pandian, P. Lindsay, M. F Grupper, and I. Rautalin, “World Stroke Organization: Global Stroke Fact Sheet 2025,” *International Journal of Stroke: Official Journal of the International Stroke Society*, vol. 20, no. 2, pp. 132–144, Feb. 2025.
- [29] World Health Organization, “Assistive technology,” 2024, fact sheet, accessed 2026.
- [30] Secretaría de Salud, “En 2021, ictus o enfermedad vascular cerebral ocasionó más de 37 mil decesos en México,” 2022, comunicado de prensa.
- [31] Instituto Nacional de Estadística y Geografía, “Encuesta Nacional de la Dinámica Demográfica (ENADID) 2023,” 2024, comunicado de prensa, 22 de mayo de 2024.
- [32] INEGI, “Estadísticas a propósito del día internacional de las personas con discapacidad,” 2024, comunicado de prensa núm. 684/24.
- [33] A. Abdullah, Z. Kausar, A. Hameed, S. R. Shiekh, and H. Khan, “Patient’s intention detection and control for sit-stand mechanism of an assistive device for paraplegics,”

- Biomedical Signal Processing and Control*, vol. 68, p. 102627, Jul. 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S174680942100224X>
- [34] MindRove, “MindRove/MindRoveSDK,” Apr. 2026, original-date: 2022-10-17T11:00:23Z. [Online]. Available: <https://github.com/MindRove/MindRoveSDK>
- [35] “Biosignalsplux User Manual,” Nov. 2023, user manual. [Online]. Available: <https://www.pluxbiosignals.com/pages/biosignalsplux>
- [36] P. Walkington, “PyoMyo,” Nov. 2021, original-date: 2021-08-08T12:16:15Z. [Online]. Available: <https://github.com/PerlinWarp/pyomyo>
- [37] P. Falkowski, J. Oleksiuk, K. Jeznach, and M. E. Aktan, “Method of automatic biomedical signals interpretation for safety supervision and optimisation of the exoskeleton-aided physiotherapy of lower extremity,” in *Proceedings of the 2024 4th International Conference on Robotics and Control Engineering*, ser. RobCE '24. New York, NY, USA: Association for Computing Machinery, Aug. 2024, pp. 57–63. [Online]. Available: <https://doi.org/10.1145/3674746.3674793>
- [38] S. Lei, G. Jialong, A. Honglei, and M. Hongxu, “Data Analysis of MYO Signals during Upper Limb Movements of Enhanced Exoskeleton,” *Journal of Physics: Conference Series*, vol. 1576, no. 1, p. 012041, Jun. 2020, publisher: IOP Publishing. [Online]. Available: <https://doi.org/10.1088/1742-6596/1576/1/012041>
- [39] Gyula, “Processing brain signals with machine learning,” PhD Thesis, Óbuda University, Budapest, 2025.
- [40] B. Taheri, D. Case, and E. Richer, “Design and Development of a Human Arm Joint Simulator for Evaluation of Active Assistive Devices Control Algorithms.” American Society of Mechanical Engineers Digital Collection, Sep. 2013, pp. 707–714. [Online]. Available: <https://dx.doi.org/10.1115/DSCC2012-MOVIC2012-8707>
- [41] A. Hussain, K. Case, R. Marshall, and S. Summerskill, “Joint mobility and inclusive design challenges,” *International Journal of Industrial Ergonomics*, vol. 53, pp. 67–79, May 2016. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S01691411530038X>

- [42] T. Bucho, G. Caetano, A. Vourvopoulos, F. Accoto, I. Esteves, S. B. i Badia, A. Rosa, and P. Figueiredo, “Comparison of Visual and Auditory Modalities for Upper-Alpha EEG-Neurofeedback,” in *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Jul. 2019, pp. 5960–5966, iSSN: 1558-4615. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/8856671>
- [43] Python Software Foundation, “Python 3.10 documentation,” 2021, versión utilizada: Python 3.10.x (64-bit).
- [44] —, “Python 3.9 documentation,” 2020, serie Python 3.9 (legacy). Entorno usado: Python 3.9.x (32-bit) en Windows. [Online]. Available: <https://docs.python.org/3.9/>
- [45] A. Hyvärinen and E. Oja, “Independent component analysis: algorithms and applications,” *Neural Networks*, 2000.
- [46] G. Pfurtscheller and F. H. Lopes da Silva, “Event-related EEG/MEG synchronization and desynchronization: basic principles,” *Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology*, vol. 110, no. 11, pp. 1842–1857, Nov. 1999.
- [47] H. Ramoser, J. Müller-Gerking, and G. Pfurtscheller, “Optimal spatial filtering of single trial EEG during imagined hand movement,” *IEEE transactions on rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society*, vol. 8, no. 4, pp. 441–446, Dec. 2000.
- [48] J. Niu and N. Jiang, “Pseudo-online detection and classification for upper-limb movements,” *Journal of Neural Engineering*, vol. 19, no. 3, p. 036042, Jun. 2022. [Online]. Available: <https://doi.org/10.1088/1741-2552/ac77be>
- [49] N. Nazmi, M. A. Abdul Rahman, S.-I. Yamamoto, S. A. Ahmad, H. Zamzuri, and S. A. Mazlan, “A Review of Classification Techniques of EMG Signals during Isotonic and Isometric Contractions,” *Sensors*, vol. 16, no. 8, p. 1304, Aug. 2016.
- [50] A. Obukhov, M. Krasnyansky, Y. Merkuryev, and M. Rybachok, “Development of a System for Recognising and Classifying Motor Activity to Control an Upper-Limb Exoskeleton,” *Applied System Innovation*, vol. 8, no. 4, p. 114, Aug. 2025. [Online]. Available: <https://www.mdpi.com/2571-5577/8/4/114>

- [51] T. Akiba, S. Sano, T. Yanase, T. Ohta, and M. Koyama, “Optuna: A next-generation hyperparameter optimization framework,” in *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2019.
- [52] B. Maldonado, “Controlador Adaptable De Rigidez Para Rehabilitación De Extremidades Superiores Asistida Por Robóts,” Tesis De Doctorado, Universidad Autónoma de San Luis Potosí, San Luis Potosí, S.L.P., Jul. 2020.
- [53] M. O. Mendoza-Gutiérrez, V. I. Ramírez-Vera, I. Bonilla-Gutiérrez, E. J. González-Galván, and A. Loredó-Flores, “Bounded Human–Robot Interaction Control Using Joint Torque Estimation From Electromyographic Signals,” *IEEE Access*, vol. 13, pp. 36 775–36 794, 2025. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/10900371>
- [54] C. Chávez-Olivares, F. Reyes-Cortés, E. González-Galván, M. Mendoza-Gutierrez, and I. Bonilla-Gutierrez, “Experimental Evaluation of Parameter Identification Schemes on an Anthropomorphic Direct Drive Robot,” *International Journal of Advanced Robotic Systems*, vol. 9, no. 5, p. 203, Nov. 2012, publisher: SAGE Publications. [Online]. Available: <https://doi.org/10.5772/52190>
- [55] National Instruments, *LabVIEW 2014 Real-Time Module Readme*, Jun. 2014, version 14.0.0. Desarrollo en LabVIEW 2014 (32-bit) sobre Windows. [Online]. Available: <https://www.ni.com/pdf/manuals/374714a.html>
- [56] B. Maldonado-Fregoso, M. Mendoza-Gutierrez, I. Bonilla-Gutierrez, and C. Vidrios-Serrano, “A generalized adaptive stiffness control scheme for robot manipulators with bounded inputs,” *Asian Journal of Control*, vol. 23, no. 6, pp. 2550–2564, 2021. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1002/asjc.2393>
- [57] N. T. Antony and P. J. Keir, “Effects of posture, movement and hand load on shoulder muscle activity,” *Journal of Electromyography and Kinesiology: Official Journal of the International Society of Electrophysiological Kinesiology*, vol. 20, no. 2, pp. 191–198, Apr. 2010.
- [58] S. A. Jayasinghe, R. L. Sainburg, and F. R. Sarlegna, “Role of proprioception in corrective visually-guided movements: larger movement errors in both arms of a deafferented individual compared to control participants,” *Experimental brain*

- research*, vol. 242, no. 10, pp. 2329–2340, Oct. 2024. [Online]. Available: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11905829/>
- [59] I. Luna-Hernández, M. Mendoza-Gutiérrez, and I. Bonilla-Gutiérrez, “From Signals to Intention: Design and Evaluation of an Optimized EEG-SEMG-IMU Approach for Real-Time Assistive Control,” in *XLVIII Mexican Conference on Biomedical Engineering*, E. Zuñiga-Aguilar, B. Benítez-Mata, J. J. Reyes-Lagos, H. Y. Hernandez Acosta, A. I. Botello Arredondo, R. Bayareh Mancilla, J. F. Vázquez de la Rosa, and C. A. Gutiérrez Valenzuela, Eds. Cham: Springer Nature Switzerland, 2026, pp. 189–198.
- [60] P. H. Gandhi, P. A. Gokhale, H. B. Mehta, and C. J. Shah, “A Comparative Study of Simple Auditory Reaction Time in Blind (Congenitally) and Sighted Subjects,” *Indian Journal of Psychological Medicine*, vol. 35, no. 3, pp. 273–277, 2013. [Online]. Available: <https://pmc.ncbi.nlm.nih.gov/articles/PMC3821205/>
- [61] D. L. Woods, J. M. Wyma, E. W. Yund, T. J. Herron, and B. Reed, “Factors influencing the latency of simple reaction time,” *Frontiers in Human Neuroscience*, vol. 9, p. 131, Mar. 2015. [Online]. Available: <https://pmc.ncbi.nlm.nih.gov/articles/PMC4374455/>
- [62] Hocoma, “Armeopower: Intended use and indications,” <https://www.hocoma.com/us/solutions/armeo-power/intended-use-indications/>, 2026, consultado el 7 de junio de 2026.
- [63] —, “Armeospring: Technical data sheet,” <https://www.hocoma.com/us/solutions/armeo-spring-2/technical-data-sheet/>, 2026, consultado el 7 de junio de 2026.
- [64] Ekso Bionics, “Eksoue: Upper extremity exoskeleton,” <https://eksobionics.com/robotic-rehab-options-for-spinal-cord-injury/>, 2021, consultado el 7 de junio de 2026.
- [65] Myomo, “What is a myopro orthosis?” <https://myomo.com/what-is-a-myopro-orthosis/>, 2026, consultado el 7 de junio de 2026.
- [66] I. B. Abdallah, Y. Bouteraa, and A. Alotaibi, “A hybrid EMG–EEG interface for robust intention detection and fatigue-adaptive control of an elbow rehabilitation robot,” *Scientific Reports*, vol. 15, no. 1, p. 40895, Nov. 2025. [Online]. Available: <https://www.nature.com/articles/s41598-025-24831-w>
- [67] T. Sultan, G. Liu, P. Sikorski, S. Alshathri, W. El-Shafai, and M. Babaiasl, “NeuroFusion-Trans: A Novel Transformer-Based EEG-EMG Fusion Model for Assistive

- Robotics,” *IEEE Access*, vol. 13, pp. 103 245–103 263, 2025. [Online]. Available: <https://ieeexplore.ieee.org/document/11028041>
- [68] S. Chikhi, N. Matton, and S. Blanchet, “EEG power spectral measures of cognitive workload: A meta-analysis,” *Psychophysiology*, vol. 59, no. 6, p. e14009, Jun. 2022.
- [69] Y. Tran, A. Craig, R. Craig, R. Chai, and H. Nguyen, “The influence of mental fatigue on brain activity: Evidence from a systematic review with meta-analyses,” *Psychophysiology*, vol. 57, no. 5, p. e13554, May 2020.

Apéndice

A. Formato de consentimiento informado

En este apéndice se incluye el formato de consentimiento informado utilizado durante el protocolo experimental. El documento describe el objetivo del estudio, los requisitos de participación, el procedimiento experimental, los posibles riesgos y beneficios, el manejo confidencial de los datos, los derechos del participante y el consentimiento documentado para ambas sesiones.

10 de abril de 2025

Carta de Consentimiento Informado para la Participación en un Estudio de Investigación

Título del estudio: Detección de la intención del usuario en tareas de interacción humano-robot.

Investigadores: Dr.Marco Octavio Mendoza Gutiérrez, Dra. Isela Bonilla Gutiérrez, I.B.M. Iván Alberto Luna Hernández.

Información de contacto: marco.mendoza@uaslp.mx, isela.bonilla@uaslp.mx, a291280@alumnos.uaslp.mx

Institución: Facultad de Ciencias, Universidad Autónoma de San Luis Potosí (UASLP).

Introducción

Antes de aceptar participar en este estudio, debe informarse sobre los propósitos, procedimientos y cualquier posible riesgo o beneficio. Usted recibirá una explicación clara del protocolo y sus implicaciones, conforme al **artículo 21 del Reglamento de la Ley General de Salud en Materia de Investigación para la Salud** y el **apartado 10.8 de la NOM-012-SSA3-2012**, actualización vigente de la norma relativa a investigación en seres humanos.

Este estudio tiene como finalidad adquirir señales de electroencefalografía (EEG) y electromiografía de superficie (sEMG) durante tareas motoras e imaginación motora del miembro superior derecho. Estas señales serán utilizadas para entrenar algoritmos de reconocimiento de intención motora aplicables a sistemas de rehabilitación robótica. El protocolo contempla dos sesiones en días distintos para cada participante, realizadas en instalaciones del Laboratorio de Robótica de la Facultad de Ciencias.

Requisitos de Participación

- Tener entre 18 y 30 años.

10 de abril de 2025

- No presentar antecedentes de enfermedades neurológicas, musculares o dermatológicas en la zona de colocación de electrodos.
- No estar bajo medicación psiquiátrica o neuromuscular.
- Dormir al menos 6 horas la noche previa a cada sesión.
- No haber consumido alcohol o drogas 12 horas antes.

Procedimientos del Estudio

Cada participante asistirá a dos sesiones experimentales, en días distintos, con una duración aproximada de 40 minutos por sesión.

Durante el estudio se registrarán señales de:

- **EEG:** mediante el dispositivo MindRove ARC, con electrodos colocados en la región central del cuero cabelludo, abarcando zonas equivalentes a C1–C6.
- **sEMG:** mediante los sistema Biosignalsplux y MYO armband, registrando señales de músculos específicos del brazo derecho según el bloque experimental:
 - *Bloque 1:* bíceps braquial y tríceps braquial.
 - *Bloque 2:* deltoides anterior y posterior.
 - *Bloque 3:* subescapular y pectoral mayor.

Las tareas consisten en la ejecución e imaginación de movimientos de flexión/extensión del codo y hombro, así como rotaciones de hombro. En los ensayos se usará una pesa de 0.88 kg para simular movilidad reducida. Todo el protocolo se realiza con los ojos cerrados y siguiendo instrucciones auditivas.

Riesgos y Beneficios

No se anticipan riesgos graves. Los electrodos no invasivos pueden causar leve incomodidad o enrojecimiento en la piel. El uso de la pesa puede inducir ligera fatiga

10 de abril de 2025

muscular. No hay beneficios personales directos, pero los datos obtenidos contribuirán al desarrollo de sistemas personalizados de rehabilitación asistida por robots.

Privacidad y Confidencialidad

La información será tratada de forma anónima mediante códigos. Solo los investigadores del proyecto tendrán acceso a los datos originales. Los resultados podrán ser utilizados con fines académicos o científicos, manteniendo el anonimato del participante.

Derechos del Participante

Su participación es completamente voluntaria. Puede retirarse del estudio en cualquier momento sin repercusiones. Tiene derecho a formular preguntas y recibir respuesta clara antes, durante o después del estudio. En caso de dudas, puede contactar al equipo investigador mediante los correos electrónicos proporcionados.

Consentimiento Documentado

He leído este documento, comprendo sus propósitos y acepto participar de forma voluntaria en ambas sesiones del estudio.

Sesión 1

Nombre y firma del participante

Nombre y firma del investigador

Sesión 2

Nombre y firma del participante

Nombre y firma del investigador

B. Entornos e implementaciones computacionales

Tabla B.1. Entornos, bibliotecas e implementaciones computacionales utilizadas.

Componente	Biblioteca o entorno	Implementación utilizada
Equipo de cómputo	AMD Ryzen 7 7735HS; 16 GB de RAM	Computadora con procesador de arquitectura x64 y sistema operativo de 64 bits.
Sistema operativo	Windows 11 de 64 bits	Entorno utilizado para la adquisición, el procesamiento, el entrenamiento y el análisis de resultados.
Procesamiento principal	Python 3.10.11	Adquisición y sincronización de señales, extracción de características, clasificación y análisis de datos.
Clasificación y validación	<i>scikit-learn</i> 1.6.1	Clase SVC para los clasificadores SVM; clase CalibratedClassifierCV para obtener probabilidades calibradas; y StratifiedKFold para la validación interna.
Limpieza de EEG	<i>scikit-learn</i> 1.6.1	Clase FastICA , con blanqueamiento de varianza unitaria, semilla fija y un máximo de 1000 iteraciones.
Optimización de hiperparámetros	Optuna 4.3.0	Estudios de un solo objetivo con 250 ensayos y seis procesos de ejecución paralela.
Modelos lineales mixtos	<i>statsmodels</i> 0.14.6	Clase MixedLM , con intercepto aleatorio por sujeto.
Procesamiento numérico	NumPy 2.2.5; SciPy 1.15.3; pandas 2.2.3	Operaciones matriciales, filtrado, estimación espectral, integración numérica, estructuración y almacenamiento de datos.
Control en tiempo real	LabVIEW Real-Time 2014	Comunicación UDP, máquina de estados, generación de referencias articulares y control del exoesqueleto mediante el cRIO.

C. Configuración de parámetros para el controlador utilizado

Tabla C.1. Valores generales de saturación y ganancia adaptativa utilizados en la configuración del controlador.

Índice	Saturación	Gamma
1	2	10
2	2	10
3	2	10
4	2	10
5	2	10
6	0.0001	0.01
7	0.0001	0.01
8	2	10
9	2	10
10	2	10
11	2	10
12	2	10
13	2	10
14	2	10
15	2	10
16	2	10
17	0.001	10
18	5	10
19	2	10
20	2	10
21	2	10

Nota. Saturación corresponde al valor límite aplicado a las funciones saturadas del controlador. Gamma corresponde a una ganancia de adaptación/configuración utilizada en la implementación del controlador, distinta de la matriz regresora $Y(q, \dot{q}, \ddot{q})$ y del vector de parámetros estimados $\hat{\theta}$.

Tabla C.2. Parámetros del controlador de impedancia con acciones acotadas para el modelo de tres grados de libertad, agrupados por motor.

Motor	freq	K_p	K_d	M_p	M_d	M_e	ϵ
inf	0.04	40	40	14	14	4.5	0.001
med	0.04	250	250	90	90	4.5	0.001
sup	0.02	100	100	20	10	4.5	0.0001

Nota. *inf*, *med* y *sup* corresponden a los motores inferior, medio y superior del exoesqueleto, respectivamente. K_P y K_D son las ganancias proporcional y derivativa; M_P , M_D y M_E son las cotas de saturación asociadas a las acciones proporcional, derivativa y de interacción; ϵ es un parámetro auxiliar pequeño de la ley adaptativa utilizado para regular la actualización de los parámetros estimados.

D. Configuración de parámetros para las reglas de estados

Tabla D.1. Parámetros configurados en LabVIEW para las reglas de transición de la máquina de estados y la generación de referencias.

Parámetro	Valor	Unidad	Función
<code>enter_ms</code>	20	ms	Tiempo mínimo para aceptar la entrada a un estado de asistencia.
<code>flip_ms</code>	20	ms	Tiempo mínimo para aceptar un cambio directo entre flexión y extensión.
<code>hold_ms</code>	250	ms	Tiempo durante el cual se mantiene el último estado válido ante pérdidas breves de intención.
<code>brake_ms</code>	120	ms	Duración del estado de frenado antes de regresar a reposo.
<code>watchdog_ms</code>	10000	ms	Tiempo máximo sin recibir paquetes válidos antes de forzar un estado seguro.
<code>q_E</code>	-20	grados	Posición objetivo asociada al estado de extensión.
<code>q_N</code>	0	grados	Posición neutra o de reposo del exoesqueleto.
<code>q_F</code>	45	grados	Posición objetivo asociada al estado de flexión.
<code>v_max</code>	15	grados/s	Velocidad máxima utilizada para limitar la generación de la referencia suave.

Nota. Los parámetros temporales regulan la estabilidad de la máquina de estados y evitan que decisiones aisladas, pérdidas breves de comunicación o fluctuaciones del clasificador produzcan cambios abruptos en la referencia enviada al controlador. Los valores `q_E`, `q_N` y `q_F` definen las posiciones articulares objetivo para extensión, reposo y flexión, respectivamente, mientras que `v_max` limita la velocidad máxima permitida durante la generación de la trayectoria de referencia.

E. Configuración del Banco CSP

Tabla E.1. Banco CSP final utilizado en L2.

Índice	Subbanda (Hz)
1	8–14
2	14–20
3	20–26
4	26–32

Nota: El banco fue generado con $n_csp = 2$ y una configuración de solape de bandas (fov) del 15 % en la construcción del banco.

F. Características crudas calculadas

Tabla F.1. Resumen de características extraídas (crudas) para el clasificador L1.

Señal	Índole	Características
EEG	Espectrales (8–30 Hz)	eeg_ratio_beta_mu, eeg_log_mu, eeg_log_beta, eeg_logvar_8_30, eeg_actrel_8_30, eeg_specent_8_30
	Eventos relacionados (ERD)	eeg_erd_mu, eeg_erd_beta
	Hjorth	eeg_hjorth_mob, eeg_hjorth_comp
	Total EEG 10 características	
sEMG	Tiempo	rms, mav, var, zc
Biosignals	Bandas	bp_20_45, bp_55_95, bp_95_200, bp_200_350
	Frecuencia	mnf (mean freq), mdf (median freq), sent (spectral entropy)
	Total sEMG Biosignals 22 características	
sEMG MYO	Tiempo	rms, mav, var, zc
	Bandas	bp_20_45, bp_55_90
	Frecuencia	mnf, mdf, sent
Total sEMG MYO (9 caract. por 8 canales) 72 características		
IMU	Acelerómetro	accx/accy/accz/accmag × (mean, std, rng)
	Giroscopio	gyrox/gyroy/gyroz/gyromag × (mean, std, rng)
	Total IMU 24 características	
Total 128 características		

Tabla F.2. Resumen de características extraídas (crudas) para el clasificador L2.

Señal	Índole	Características
EEG	Espectrales (8–30 Hz)	eeg_ratio_beta_mu, eeg_log_mu,
		eeg_log_beta, eeg_logvar_8_30,
		eeg_actrel_8_30, eeg_specent_8_30
	Eventos relacionados (ERD)	eeg_erd_mu, eeg_erd_beta
	Hjorth CSP	eeg_hjorth_mob, eeg_hjorth_comp csp_1, csp_2, csp_3, csp_4, csp_5, csp_6, csp_7, csp_8
<i>Total EEG 18 características</i>		
sEMG	Tiempo	rms, mav, var, zc
	Bandas	bp_20_45, bp_55_95, bp_95_200,
	Frecuencia	bp_200_350, bp_55_90 mnf (mean freq), mdf (median freq), sent (spec- tral entropy)
<i>Total sEMG Biosignals 24 características</i>		
sEMG MYO	Tiempo	rms, mav, var, zc (8c)
	Bandas	bp_20_45, bp_55_90 (6c)
	Frecuencia	mnf, mdf, sent (6c)
<i>Total sEMG MYO 62 características</i>		
IMU	Acelerómetro	accx/accy/accz/accmag × (mean, std, rng)
	Giroscopio	gyrox/gyroy/gyroz/gyromag × (mean, std, rng)
<i>Total IMU 24 características</i>		
Total 128 características		

G. Características después de limpieza de redundancias

Tabla G.1. Características por modalidad para L1.

Modalidad	Características
EEG	eeg_ratio_beta_mu, eeg_log_mu, eeg_log_beta, eeg_spect_8_30, eeg_hjorth_mob, eeg_hjorth_comp, eeg_logvar_8_30, eeg_erd_mu, eeg_erd_beta, eeg_actrel_8_30
sEMG Bio	emg_0_var, emg_1_var, emg_0_rms, emg_1_rms, emg_1_zc, emg_0_zc, emg_1_mdf, emg_0_mdf, emg_0_bp_55_95, emg_1_bp_55_95, emg_0_sent, emg_1_sent
sEMG Myo	myoemg_0_var, myoemg_1_var, myoemg_7_var, myoemg_4_var, myoemg_2_var, myoemg_6_var, myoemg_5_var, myoemg_2_zc, myoemg_0_zc, myoemg_1_zc, myoemg_5_zc, myoemg_7_zc, emg_1_mdf, myoemg_6_zc, emg_0_mdf, myoemg_2_mdf, myoemg_6_mdf, myoemg_1_mdf, myoemg_0_mdf, myoemg_7_mdf, myoemg_3_mdf, myoemg_5_mdf, myoemg_4_mdf, myoemg_3_rms, myoemg_7_bp_20_45, myoemg_0_bp_20_45, myoemg_4_bp_55_90, myoemg_2_bp_55_90, myoemg_1_bp_55_90, myoemg_6_bp_55_90, myoemg_3_bp_20_45, myoemg_5_bp_20_45, myoemg_7_sent, myoemg_0_sent, myoemg_6_sent, myoemg_1_sent, myoemg_2_sent, myoemg_3_sent, myoemg_5_sent, myoemg_4_sent
IMU	gyromag_rng, gyrox_rng, gyroz_rng, gyromag_mean, gyroy_mean, gyroz_mean, gyrox_mean, accz_mean, accy_mean, accx_mean, accx_rng, accz_rng, accy_rng, accmag_rng, accmag_mean

Tabla G.2. Características por modalidad para L2 (parte 1/2).

Modalidad	Características
EEG	eeg_ratio_beta_mu, eeg_log_mu, eeg_log_beta, eeg_spect_8_30, eeg_hjorth_mob, eeg_hjorth_comp, eeg_logvar_8_30, eeg_erd_mu, eeg_erd_beta, eeg_actrel_8_30, csp_1, csp_2, csp_3, csp_4, csp_5, csp_6, csp_7, csp_8
sEMG Bio	emg_0_var, emg_1_var, emg_0_rms, emg_1_rms, emg_0_mav, emg_1_mav, emg_1_zc, emg_0_zc, emg_0_bp_55_95, emg_0_bp_20_45, emg_1_bp_55_95, emg_1_bp_20_45

Tabla G.3. Características por modalidad para L2 (parte 2/2).

Modalidad	Características
sEMG Myo	emg_1_mnf, emg_1_mdf, emg_0_mnf, emg_0_mdf, emg_2_mdf, emg_6_mdf, emg_7_mdf, emg_3_mdf, emg_5_mdf, emg_4_mdf, emg_2_mnf, emg_6_mnf, emg_7_mnf, emg_5_mnf, emg_3_mnf, emg_4_mnf, emg_7_bp_20_45, emg_0_bp_55_90, emg_7_bp_55_90, emg_1_bp_95_200, emg_0_bp_200_350, emg_4_bp_55_90, emg_3_bp_55_90, emg_2_bp_55_90, emg_1_bp_55_90, emg_5_bp_55_90, emg_6_bp_55_90, emg_4_bp_20_45, emg_2_bp_20_45, emg_6_bp_20_45, emg_3_bp_20_45, emg_5_bp_20_45, emg_1_bp_200_350, emg_0_sent, emg_1_sent, emg_7_sent, emg_6_sent, emg_2_sent, emg_3_sent, emg_5_sent, emg_4_sent, myoemg_0_var, myoemg_1_var, myoemg_7_var, myoemg_4_var, myoemg_3_var, myoemg_2_var, myoemg_6_var, myoemg_5_var, myoemg_2_zc, myoemg_0_zc, myoemg_1_zc, myoemg_5_zc, myoemg_3_zc, myoemg_4_zc, myoemg_7_zc, myoemg_6_zc, myoemg_0_rms, myoemg_7_rms, myoemg_1_rms, myoemg_0_mav, myoemg_4_rms, myoemg_3_rms, myoemg_2_rms, myoemg_7_mav, myoemg_1_mav, myoemg_4_mav, myoemg_6_rms, myoemg_5_rms, myoemg_3_mav, myoemg_2_mav, myoemg_6_mav, myoemg_5_mav
IMU	gyromag_rng, gyrox_rng, gyroy_rng, gyroz_rng, gyromag_mean, gyroy_mean, gyroz_mean, gyromag_std, gyroy_std, gyroz_std, gyrox_mean, accz_mean, accy_mean, accx_mean, accx_rng, accz_rng, accy_rng, accmag_rng, accx_std, accz_std, accy_std, accmag_std, accmag_mean

H. Media e intervalo de confianza al 95 %

Tabla H.1. Media e intervalo de confianza al 95 % (IC95 %) de la precisión por condición y grupo de generalización.

Grupo	Condición	Media	IC _{95 %} (bajo)	IC _{95 %} (alto)	<i>n</i>
Conocidos					
	OC_pequeña	0.8790	0.8650	0.8952	5
	OC_grande	0.8278	0.7814	0.8718	5
	OA_grande	0.8728	0.8414	0.8920	5
	OC_nada	0.8796	0.8368	0.9132	5
Desconocidos					
	OC_pequeña	0.8790	0.8530	0.9098	5
	OC_grande	0.8502	0.7900	0.9056	5
	OA_grande	0.8850	0.8690	0.9010	5
	OC_nada	0.8400	0.7982	0.8856	5

Tabla H.2. Media e intervalo de confianza al 95 % (IC95 %) de la sensibilidad por condición y grupo de generalización.

Grupo	Condición	Media	IC _{95 %} (bajo)	IC _{95 %} (alto)	<i>n</i>
Conocidos					
	OC_pequeña	0.8410	0.7970	0.8716	5
	OC_grande	0.7778	0.7198	0.8340	5
	OA_grande	0.8418	0.7920	0.8792	5
	OC_nada	0.8128	0.7384	0.8842	5
Desconocidos					
	OC_pequeña	0.8594	0.8102	0.9038	5
	OC_grande	0.8330	0.7658	0.8924	5
	OA_grande	0.8430	0.7764	0.8954	5
	OC_nada	0.7936	0.6916	0.8826	5

Tabla H.3. Media e intervalo de confianza al 95 % (IC95 %) de la latencia (ms) por condición y grupo de generalización.

Grupo	Condición	Media (ms)	IC _{95 %} (bajo)	IC _{95 %} (alto)	<i>n</i>
Conocidos					
	OC_pequeña	54.20	42.38	66.86	5
	OC_grande	50.85	46.09	55.61	5
	OA_grande	51.95	47.48	55.29	5
	OC_nada	49.60	42.26	56.24	5
Desconocidos					
	OC_pequeña	53.88	46.54	61.84	5
	OC_grande	52.78	49.84	56.46	5
	OA_grande	59.94	55.32	64.56	5
	OC_nada	53.98	48.76	59.20	5

I. Resúmenes de modelos de ajuste para efecto aleatorio

Tabla I.1. Modelo lineal mixto implementado mediante *MixedLM* para precisión con intercepto aleatorio por sujeto.

Efecto	Coef.	EE	z	p	IC95 % inf.	IC95 % sup.
Intercepto	0.879	0.018	48.176	0.000	0.843	0.915
grupo desconocido	0.000	0.026	0.000	1.000	-0.051	0.051
OC_grande	-0.051	0.022	-2.334	0.020	-0.094	-0.008
OA_grande	-0.006	0.022	-0.283	0.777	-0.049	0.037
OC_nada	0.001	0.022	0.027	0.978	-0.042	0.044
grupo desconocido × OC_grande	0.022	0.031	0.722	0.470	-0.038	0.083
grupo desconocido × OA_grande	0.012	0.031	0.393	0.694	-0.049	0.073
grupo desconocido × OC_nada	-0.040	0.031	-1.276	0.202	-0.100	0.021
Var(sujeto)	0.000	0.011				

Nota. Referencia: grupo conocido en OC_pequeña. Los coeficientes indican diferencias respecto a esa referencia; las interacciones indican el efecto adicional del grupo desconocido. EE = error estándar; IC95 % = intervalo de confianza al 95 %; Var(sujeto) = varianza del intercepto aleatorio.

Tabla I.2. Modelo lineal mixto implementado mediante *MixedLM* para sensibilidad con intercepto aleatorio por sujeto.

Efecto	Coef.	EE	z	p	IC95 % inf.	IC95 % sup.
Intercepto	0.841	0.032	26.157	0.000	0.778	0.904
grupo desconocido	0.018	0.045	0.405	0.686	-0.071	0.108
OC_grande	-0.063	0.038	-1.653	0.098	-0.138	0.012
OA_grande	0.001	0.038	0.021	0.983	-0.074	0.076
OC_nada	-0.028	0.038	-0.738	0.461	-0.103	0.047
grupo desconocido × OC_grande	0.037	0.054	0.681	0.496	-0.069	0.143
grupo desconocido × OA_grande	-0.017	0.054	-0.318	0.750	-0.123	0.089
grupo desconocido × OC_nada	-0.038	0.054	-0.695	0.487	-0.144	0.068
Var(sujeto)	0.002	0.021				

Nota. Referencia: grupo conocido en OC_pequeña. Los coeficientes indican diferencias respecto a esa referencia; las interacciones indican el efecto adicional del grupo desconocido. EE = error estándar; IC95 % = intervalo de confianza al 95 %; Var(sujeto) = varianza del intercepto aleatorio.

Tabla I.3. Modelo lineal mixto implementado mediante *MixedLM* para latencia con intercepto aleatorio por sujeto.

Efecto	Coef.	EE	z	p	IC95 % inf.	IC95 % sup.
Intercepto	54.200	3.370	16.081	0.000	47.594	60.806
grupo desconocido	-0.320	4.766	-0.067	0.946	-9.662	9.022
OC_grande	-3.350	4.064	-0.824	0.410	-11.315	4.615
OA_grande	-2.250	4.064	-0.554	0.580	-10.215	5.715
OC_nada	-4.600	4.064	-1.132	0.258	-12.565	3.365
grupo desconocido $\times$ OC_grande	2.250	5.747	0.392	0.695	-9.014	13.514
grupo desconocido $\times$ OA_grande	8.310	5.747	1.446	0.148	-2.954	19.574
grupo desconocido $\times$ OC_nada	4.700	5.747	0.818	0.413	-6.564	15.964
Var(sujeto)	15.511	2.076				

Nota. Referencia: grupo conocido en OC_pequeña. Los coeficientes indican diferencias de latencia respecto a esa referencia; las interacciones indican el efecto adicional del grupo desconocido. EE = error estándar; IC95 % = intervalo de confianza al 95 %; Var(sujeto) = varianza del intercepto aleatorio. Observaciones = 40; sujetos = 10; método = ML; convergencia = sí.


J. Ajuste de relación precisión-latencia

Tabla J.1. Modelo lineal mixto implementado mediante *MixedLM* para precisión incluyendo latencia. Efecto aleatorio: intercepto por sujeto.


Término	Coef.	EE	z	p	IC 95 %
Intercepto	0.940	0.051	18.565	< 0.001	[0.841, 1.039]
grupo[T.desconocidos]	-0.000	0.025	-0.014	0.988	[-0.049, 0.048]
condición[T.OC_grande]	-0.055	0.022	-2.473	0.130	[-0.099, -0.011]
condición[T.OA_grande]	-0.009	0.022	-0.395	0.693	[-0.052, 0.035]
condición[T.OC_nada]	-0.005	0.022	-0.204	0.838	[-0.048, 0.039]
grupo[T.desconocidos]:condición[T.OC_grande]	0.025	0.031	0.798	0.425	[-0.036, 0.086]
grupo[T.desconocidos]:condición[T.OA_grande]	0.022	0.032	0.673	0.501	[-0.041, 0.084]
grupo[T.desconocidos]:condición[T.OC_nada]	-0.034	0.031	-1.092	0.275	[-0.096, 0.027]
<i>latencia_{ms}</i>	-0.001	0.001	-1.284	0.199	[-0.003, 0.001]
Varianza (sujeto)	0.000	0.010	(intercepto aleatorio)		

Nota. El intercepto representa la precisión estimada para la categoría de referencia: grupo conocido en la condición OC_pequeña, con la latencia incluida como covariable. Los términos de grupo, condición e interacción se interpretan como diferencias estimadas respecto a esa categoría de referencia. El término *latencia_{ms}* representa el cambio estimado en la precisión por cada milisegundo adicional de latencia. Coef. = coeficiente estimado; EE = error estándar; *z* = estadístico de prueba; *p* = valor de significancia; IC95 % = intervalo de confianza al 95 %; *Var(sujeto)* = varianza del intercepto aleatorio por sujeto.

K. Resultados experimentales para sujeto conocido




(a) Ojos cerrados y pesa pequeña.




(b) Ojos cerrados y pesa grande.

Figura K.1. Resultados experimentales en tiempo real para el sujeto 13 (conocido) en condiciones con ojos cerrados y carga externa.




(a) Ojos abiertos y pesa grande.




(b) Ojos cerrados y sin pesa.

Figura K.2. Resultados experimentales en tiempo real para el sujeto 13 (conocido) en las condiciones de ojos abiertos con carga y ojos cerrados sin carga.

L. Resultados experimentales para sujeto desconocido




(a) Ojos cerrados y pesa pequeña.




(b) Ojos cerrados y pesa grande.

Figura L.1. Resultados experimentales en tiempo real para el sujeto 20 (desconocido) en condiciones con ojos cerrados y carga externa.



(a) Ojos abiertos y pesa grande.



(b) Ojos cerrados y sin pesa.

Figura L.2. Resultados experimentales en tiempo real para el sujeto 20 (desconocido) en las condiciones de ojos abiertos con carga y ojos cerrados sin carga.