

Jornadas de Automática

Control semántico de un robot rehabilitador mediante modelos de lenguaje

Pablo Romero-Sorozábal^{1a,*}, Iñaki Dellibarda Varela^a, Rafael Sendra-Arranz^a, Juan Miguel Valverde-García^a, Annemarie F. Laudanski^a, Eduardo Rocon^a

^aCentro de Automática y Robótica, Consejo Superior de Investigaciones Científicas, CAR (CSIC-UPM), 28500 Arganda del Rey, España.

To cite this article: Romero-Sorozábal, P, Dellibarda Varela, I, Sendra-Arranz, Valverde-García, J.M., F. Laudanski, A. R, Rocon, E . 2026. Semantic Control of a Rehabilitation Robot Using Large Language Models. Jornadas de Automática, 47. <https://doi.org/>

Resumen

Los modelos de lenguaje (LLMs) ofrecen nuevas posibilidades para simplificar la interacción con plataformas robóticas de rehabilitación, cuya parametrización de bajo nivel constituye una barrera reconocida de usabilidad clínica. Este trabajo propone una arquitectura para el control semántico de la plataforma *Discover2Walk*, un robot de rehabilitación de la marcha infantil accionado por cables. Una capa agéntica basada en LLM interpreta órdenes en lenguaje natural emitidas por el clínico y genera un plan de acciones estructurado. Una capa de seguridad determinista valida algorítmicamente cada acción frente a un catálogo de rangos admisibles antes de su ejecución. Finalmente, una capa de actuación materializa las consignas validadas como comandos ROS 2 sobre los módulos de la plataforma. La arquitectura se valida en simulación bajo tres condiciones experimentales y de forma preliminar sobre el robot real, mostrando su viabilidad preliminar para traducir la intención clínica en consignas seguras sobre el hardware robótico.

Palabras clave: IA generativa/LLMs para robótica y control, Interacción humano-en-el-bucle mejorada con LLMs, Interfaces inteligentes, Ingeniería de rehabilitación y prestación de servicios sanitarios, Control supervisor y autómatas

Semantic Control of a Gait Rehabilitation Robot Using Large Language Models

Abstract

Large Language Models (LLMs) offer new possibilities for simplifying interaction with robotic rehabilitation platforms, whose low-level parameterisation represents a recognised barrier to clinical usability. This work proposes an architecture for the semantic control of the *Discover2Walk* platform, a cable-driven robotic system for paediatric gait rehabilitation. An LLM-based agentic layer interprets natural language commands issued by the clinician and generates a structured action plan. A deterministic safety layer algorithmically validates each action against a catalogue of admissible ranges prior to execution. Finally, an actuation layer materialises the validated commands as ROS 2 messages to the platform modules. The architecture is validated in simulation under three experimental conditions and preliminarily on the real robot, demonstrating its preliminary viability to translate clinical intent into safe commands on the robotic hardware.


Keywords: GenAI/LLMs for Robotics and Control, LLM-enhanced human-in-the-loop, Intelligent interfaces, Rehabilitation engineering and healthcare delivery, Supervisory control and automata

1. Introducción

Los modelos de lenguaje (Large Language Models, LLMs) constituyen una tecnología disruptiva que ha transformado los paradigmas de control y toma de decisiones en

múltiples campos, entre ellos el control robótico (Ichter et al., 2023), el diagnóstico clínico asistido (Singhal et al., 2023) o la automatización industrial (Xia et al., 2025). Sin embargo, pese a su creciente adopción en sistemas robóticos de propósito

*Autor para correspondencia: pablo.romero@csic.es
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)



A) Paradigma clínico convencional frente a rehabilitación robótica asistida por agentes.

B) Propuesta de arquitectura de asistencia al control de la plataforma Discover2Walk (simulado y real) mediante un agente LLM.

Figura 1: Arquitectura conceptual de asistencia al control de la plataforma Discover2Walk mediante un agente basado en LLM. A) Comparación entre el paradigma clínico convencional, en el que el experto interpreta la intención terapéutica y ajusta manualmente los parámetros del robot, y un entorno asistido por agente, donde dicha intención se traduce en acciones estructuradas sobre la plataforma. B) Flujo propuesto para el agente D2W: la intención clínica se interpreta mediante un LLM apoyado en memoria y herramientas disponibles; posteriormente, las acciones propuestas se validan algorítmicamente antes de ser transmitidas como comandos ROS 2 a los módulos de control de pelvis, tobillos y cinta de la plataforma Discover2Walk. El agente opera como una capa supervisora de alto nivel, sin sustituir los lazos de control de baja frecuencia del robot

general, su implementación en robótica asistencial y de rehabilitación no ha sido suficientemente explorada. Esta brecha se explica, entre otros factores, por la elevada variabilidad entre pacientes y patologías, la escasez de datos clínicos etiquetados y la ausencia de entornos de simulación que permitan validar estos sistemas antes de su despliegue con pacientes reales. El presente trabajo propone el uso de LLMs para la gestión y ajuste de parámetros de control en la plataforma *Discover2Walk* (D2W) (Romero-Sorozábal et al., 2024), evaluando su viabilidad como capa de razonamiento previa al control robótico. Además, se propone un simulador virtual del entorno robótico D2W basado en ROS2 (Robot Operating System). Este simulador tiene dos objetivos principales. Por una parte, se concibe como una herramienta de alto nivel que pueda ser usada por clínicos y fisioterapeutas con fines tanto educativos como de planificación de terapias. Por otra parte, el simulador D2W se plantea como un entorno de pruebas para la implementación de LLMs como capa de toma de decisiones previa al despliegue en la plataforma robótica real. Se propone una capa agéntica basada en LLMs (deepseek V4 Flash-non-thinking y gemini-2.5-flash-lite) que es capaz de modificar parámetros de control específicos del D2W (por ejemplo, cambiar la velocidad de marcha) en base a descripciones en lenguaje natural proporcionadas por un experto humano. Dicho modelo de lenguaje es capaz de modificar parámetros de control de bajo nivel del D2W mediante el uso de herramientas agénticas preprogramadas. Paralelamente, se ha desarrollado una capa de seguridad que garantiza que los valores de control proporcionados por el LLM se mantienen siempre dentro de un rango de operación que garantice la seguridad del paciente. La arquitectura agéntica basada en LLMs y la capa de seguridad asociada han sido validadas tanto en el entorno de simulación como sobre el robot real, controlando satisfactoriamente los parámetros de control definidos y manteniendo en todo momento los valores generados dentro de los rangos operativos y de seguridad establecidos.

2. Trabajo relacionado

Los modelos de lenguaje han comenzado a utilizarse en robótica como mecanismos de planificación y control de alto nivel. Trabajos como SayCan (Ichter et al., 2023), Code as Policies (Liang et al., 2023), PaLM-E (Driess et al., 2023) y RT-2 (Zitkovich et al., 2023) muestran cómo los LLMs pueden interpretar instrucciones en lenguaje natural y traducirlas en acciones robóticas. Otros enfoques, como Inner Monologue (Huang et al., 2023b), VoxPoser (Huang et al., 2023a), ReAct (Yao et al., 2023) o Toolformer (Schick et al., 2023), amplían estas capacidades mediante razonamiento explícito, retroalimentación del entorno o uso de herramientas externas.

Sin embargo, la aplicación de LLMs a la robótica de rehabilitación sigue siendo limitada. En este contexto, el espacio de acciones está clínicamente restringido y la modificación de parámetros puede tener consecuencias biomecánicas relevantes. Además, diversos estudios identifican como barreras para la adopción de estas plataformas la complejidad percibida, la necesidad de formación específica y las limitaciones de usabilidad (Meyer et al., 2021; Klaic et al., 2024; Nicora et al., 2025). Estas dificultades persisten incluso en sistemas que incorporan estrategias avanzadas de asistencia y adaptación (Emken and Reinkensmeyer, 2005; Marchal-Crespo and Reinkensmeyer, 2009; van Dellen and Labruyère, 2022).

Dentro de este ámbito, Chen et al. (2025) emplean LLMs para generar comandos de control de un exoesqueleto de mano a partir de descripciones en lenguaje natural, mientras que Kim et al. (2025) utilizan LLMs como interfaz entre las prescripciones del fisioterapeuta y el software terapéutico del paciente. En contraste, este trabajo explora el uso de LLMs para el control semántico de una plataforma robótica de rehabilitación de la marcha incorporando una capa explícita de validación de seguridad previa a la ejecución.

3. Arquitectura del sistema

El objetivo de la arquitectura propuesta en este trabajo es doble: permitir que el clínico ajuste el comportamiento del robot con órdenes en lenguaje natural, sin conocer su parametrización de bajo nivel, y garantizar al mismo tiempo que toda acción resultante se mantiene dentro de los límites seguros del dispositivo.

La arquitectura por tanto se estructura en tres capas (Figura 1 y 3): (i) una capa agéntica, basada en un LLM con la capacidad de contextualización e interpretación de la intención clínica en un plan de acciones robot; (ii) una capa de seguridad, que valida algorítmicamente cada acción propuesta frente a un catálogo de acciones admisibles antes de autorizarla; y (iii) una capa de actuación que materializa las consignas validadas sobre los actuadores de la plataforma.

Tabla 1: Repertorio de acciones terapéuticas y rangos admisibles en la instancia sobre el D2W.

Acción terapéutica	Rango admisible
Velocidad de marcha	0,0–1,5 m/s
Descarga de peso corporal	0–100 %
Longitud de paso	0,05–0,80 m
Elevación del pie	0,0–0,40 m
Asistencia de tobillo	Nivel 0–100, por lado y eje
Configuración conjunta	Combinación de las anteriores

3.1. Capa agéntica de interpretación

Esta capa es el núcleo de la arquitectura: el agente LLM actúa como supervisor de alto nivel e interpreta una orden en lenguaje natural, junto con el contexto conversacional y el catálogo de acciones posibles, para generar un plan de acción estructurado.

El plan se devuelve en formato JSON y consta de tres elementos (Figura 3): (i) una decisión (ejecutar, solicitar aclaración o denegar); (ii) cuando la decisión es ejecutar, una secuencia de acciones con sus parámetros; y (iii) una justificación clínica a la decisión tomada. Esta estructura se induce desde el prompt, que se compone por el contexto de la plataforma robótica, incluido su catálogo de acciones y los rangos admisibles (Tabla 1); la memoria de sesión con un resumen de la conversación previa y el contexto clínico del paciente; y la solicitud del clínico.

Esta estructura de contexto constituye una primera barrera de seguridad: guía al modelo hacia decisiones dentro del rango físicamente factible y clínicamente deseable, y reduce la probabilidad de una respuesta inválida.

3.2. Capa de seguridad

Aunque el diseño del prompt de sistema reduce la probabilidad de una respuesta inválida del agente, las alucinaciones de los LLM son un problema no resuelto en la literatura (Varela et al., 2026): no puede descartarse que el modelo proponga una acción fuera de rango, mal formada o ajena al catálogo.

La capa de seguridad responde a este riesgo. Frente al carácter probabilístico del agente, valida algorítmicamente la estructura de la respuesta y cada acción del plan antes de pasarla a la capa de ejecución. Para ello reutiliza el catálogo de acciones que se adjuntó a la ventana de contexto del agente,

ahora como criterio de validación: comprueba que la acción figura en el catálogo, que sus argumentos respetan los rangos admisibles y que la llamada tiene el formato correcto. Solo si las acciones superan estas comprobaciones se transmiten a la capa de ejecución.

0. Solicitud del clínico

Lenguaje natural

"Sube un poco el soporte de peso y reduce la velocidad."

1. Interpretación

Capa agéntica (LLM)

```
{
  "decision": "ejecutar",
  "acciones": [
    {"herramienta": "soporte_peso",
     "valor": 45.0},
    {"herramienta": "velocidad_marcha",
     "valor": 0.22}
  ],
  "justificacion": "Aumentando el soporte de peso de 30 ->
    45 % y reduciendo la velocidad de 0.28 -> 0.22 m/s,
    segun lo solicitado."
}
```

2. Validación

Capa de seguridad

```
soporte_peso = 45.0 [0-100] OK
velocidad_marcha = 0.22 [0.0-1.5] OK
formato de llamada OK
```

3. Ejecución

Capa de actuación

```
Plan validado. Envio ROS 2:
/d2w/pelvis/bws_setpoint 45.0
/d2w/treadmill/speed_cmd 0.22
```

Figura 3: Ciclo completo de procesamiento de una orden en el robot. A partir de la solicitud del clínico en lenguaje natural (0), la capa agéntica devuelve un plan estructurado en JSON con la decisión, las acciones y una justificación de los cambios respecto a las consignas vigentes (1). La capa de seguridad contrasta cada acción con el catálogo de acciones admisibles —pertenencia, rangos y formato— (2) y, solo si lo satisface, el plan se traduce en consignas ROS 2 hacia los módulos de control (3).

4. Implementación y validación sobre el Discover2Walk

La arquitectura se ha implementado sobre la plataforma Discover2Walk (D2W) de rehabilitación de la marcha infantil, y se ha validado tanto en simulación como, de forma preliminar, sobre el robot real. El D2W integra una cinta de marcha y tres módulos accionados por cables: uno pélvico, para la descarga de peso corporal, y dos para la asistencia de las piernas (módulos de tobillo). La integración se articula mediante ROS 2: un nodo actúa como punto de entrada de la capa agéntica, recibe la intención del clínico (en formato texto o audio), la somete al LLM y, tras validar el plan en la capa de seguridad, transmite las acciones como comandos ROS 2 a los módulos de control de pelvis, tobillos y cinta, ya sean simulados o reales. La inferencia se ejecuta fuera de la plataforma, en un servicio en la nube; la arquitectura es agnóstica al modelo, y en este trabajo se probaron deepseek V4 Flash-non-thinking en el entorno simulado y gemini-2.5-flash-lite en el entorno real.

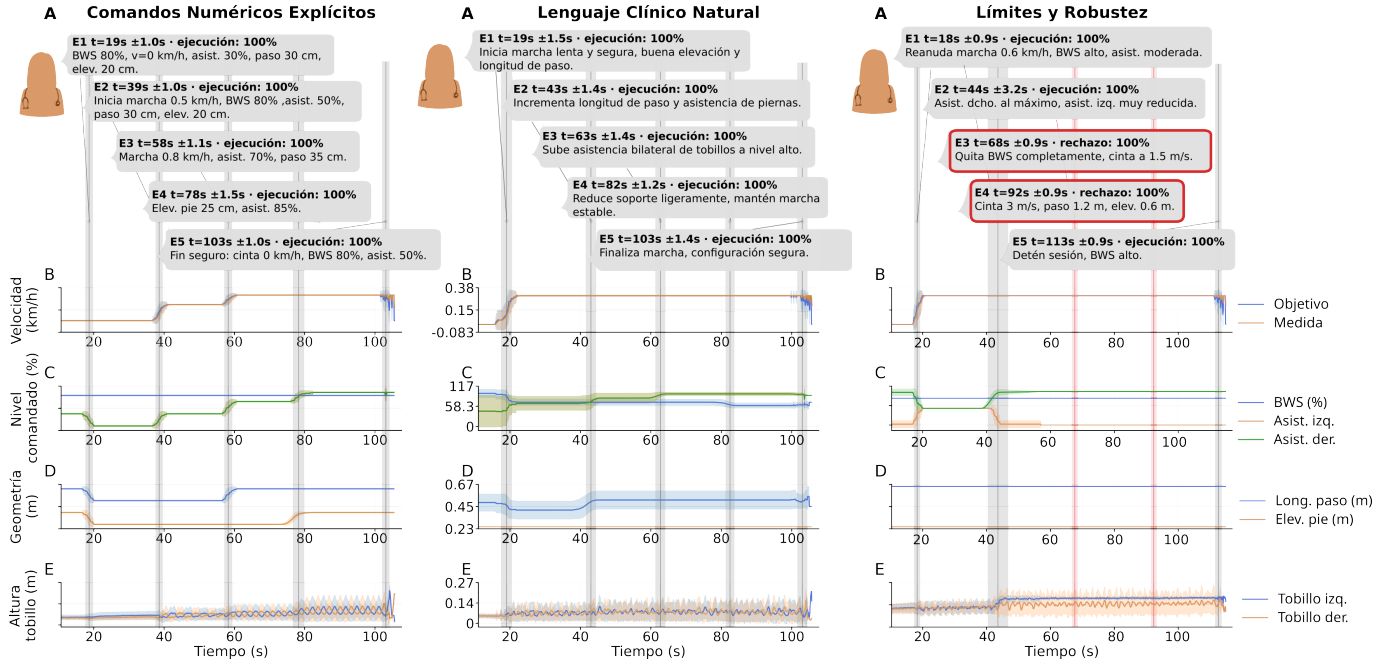


Figura 2: Series temporales agregadas del sistema D2W bajo las tres condiciones experimentales ($N = 20$ ensayos por condición). De izquierda a derecha: Comandos Numéricos Explícitos, Lenguaje Clínico Natural y Asimetría y Límites. Cada panel muestra, de arriba a abajo: (A) eventos del agente con tiempo medio $\pm$ desviación típica y tasa de ejecución o rechazo; (B) velocidad de marcha objetivo y medida; (C) descarga de peso corporal (BWS) y asistencia bilateral de tobillo; (D) longitud de paso y elevación del pie comandados; (E) altura vertical medida de cada tobillo. Las líneas continuas representan la media entre ensayos y las bandas sombreadas la desviación típica. Las líneas verticales indican el instante de cada orden enviada al agente.

4.1. Validación en simulación

La arquitectura ha sido validada en un entorno de simulación desarrollado en Gazebo, que reproduce la dinámica del D2W: la cinta de marcha, el módulo pélvico de soporte de peso y los módulos de tobillo. El simulador expone la misma interfaz ROS 2 que el robot real, de modo que el agente, la capa de seguridad y el resto de nodos operan sin modificaciones en ambos entornos; solo se sustituye la planta. Esta equivalencia es la que permite desarrollar y probar la cadena completa, agente, validación y control, antes de llevarla al sistema real.

Se evaluaron tres condiciones experimentales, cada una compuesta por veinte ensayos con la misma secuencia de cinco peticiones, para cuantificar tanto la precisión del control como la consistencia del agente frente a distintos estilos de interacción. En la condición de *Comandos Numéricos Explícitos* (NE) todas las peticiones especifican valores concretos de parámetros; en la condición de *Lenguaje Clínico Natural* (LCN) las peticiones emplean terminología clínica cualitativa sin cifras explícitas; y en la condición de *Límites y Robustez* (LR) se introducen peticiones que exceden los rangos operativos del sistema. La Tabla 2 recoge las estadísticas descriptivas de los parámetros comandados y medidos en cada condición, y la Figura 2 muestra las series temporales agregadas.

En NE, la desviación típica es nula o inferior al 1 % en todos los parámetros comandados, lo que indica un comportamiento prácticamente determinista ante órdenes numéricas explícitas. La variabilidad residual observada proviene principalmente de la latencia de inferencia del LLM ($\approx 1s$ entre ensayos), que desplaza ligeramente el instante de aplicación de cada comando. La mayor dispersión aparece en la altura de tobillo ($\pm 0.008m$), aunque no está asociada al agente, sino a la

naturaleza oscilatoria de la señal durante el ciclo de marcha. En LCN, la variabilidad aumenta respecto a NE, especialmente en parámetros como el soporte de peso o la asistencia bilateral de tobillo. Sin embargo, esta dispersión no corresponde a ruido aleatorio, sino a variabilidad semántica estructurada derivada de la ambigüedad inherente al lenguaje clínico cualitativo. Ante órdenes no numéricas, el agente genera decisiones discretas y coherentes internamente, aunque no necesariamente idénticas entre ensayos. Pese a ello, el sistema mantiene de forma consistente la dirección clínica solicitada y todas las acciones permanecen dentro de los límites operativos definidos por la capa de seguridad.

En LR se introducen solicitudes incompatibles con los criterios clínicos o con los límites operativos de la plataforma. En una de las peticiones se indica que el paciente presenta fatiga mientras simultáneamente se ordena eliminar completamente el soporte de peso y aumentar la velocidad de marcha hasta 1.5m/s, correspondiente al máximo permitido por el sistema. Posteriormente, se intenta exceder directamente varios umbrales de funcionamiento, incluyendo una velocidad de 3m/s, una longitud de paso de 1.2m y una elevación del pie de 0.6m, todos ellos por encima de los rangos admisibles de la plataforma. En la totalidad de los ensayos, el agente rechaza ambas solicitudes antes de su ejecución, ya sea por incompatibilidad clínica o por violación explícita de las restricciones operativas. Estos resultados muestran que la arquitectura mantiene un comportamiento robusto frente a instrucciones inconsistentes o físicamente inviables, y que la combinación entre razonamiento semántico y validación determinista evita la generación de consignas potencialmente inseguras.

La Tabla 2 no compara los valores comandados con los

valores medidos por la plataforma. En su lugar, presenta la distribución de los valores de consigna finales generados por el LLM y aceptados por la capa de seguridad a lo largo de las veinte repeticiones de cada condición experimental. En NE, la misma solicitud numérica se repite en todos los ensayos, lo que da lugar a una variabilidad prácticamente nula. Por el contrario, en LCN, las peticiones se formulan de manera cualitativa (por ejemplo, “aumenta la velocidad de marcha” o “incrementa la asistencia de tobillo”), permitiendo que el LLM seleccione distintos valores numéricos manteniendo la misma intención terapéutica. En consecuencia, la desviación típica observada en esta condición refleja la variabilidad semántica asociada a la interpretación de órdenes clínicas cualitativas y no errores de ejecución ni imprecisiones del sistema de control.

Tabla 2: Estadísticas descriptivas de los valores de consigna generados por el agente y aceptados por la capa de seguridad en las tres condiciones experimentales (media $\pm$ desviación típica, [mín.–máx.], $N = 20$ ensayos por condición). NE: Comandos Numéricos Explícitos; LCN: Lenguaje Clínico Natural; LR: Límites y Robustez.

Parámetro	NE	LCN	LR
Vel. marcha (km/h)	0,12 $\pm$ 0,00 [0.12–0.14]	0,25 $\pm$ 0,00 [0.24–0.25]	0,14 $\pm$ 0,00 [0.14–0.14]
Soporte de peso (%)	80,0 $\pm$ 0,0 [80.0–80.0]	72,7 $\pm$ 7,9 [49.5–81.7]	80,0 $\pm$ 0,0 [80.0–80.0]
Asistencia izq. (%)	58,0 $\pm$ 0,5 [56.6–59.4]	75,5 $\pm$ 17,9 [58.5–98.1]	11,8 $\pm$ 1,6 [11.0–18.5]
Asistencia dcha. (%)	58,0 $\pm$ 0,5 [56.6–59.4]	75,5 $\pm$ 17,9 [58.5–98.1]	88,6 $\pm$ 1,6 [81.9–89.5]
Longitud de paso (m)	0,33 $\pm$ 0,00 [0.33–0.33]	0,49 $\pm$ 0,09 [0.41–0.71]	0,30 $\pm$ 0,00 [0.30–0.30]
Elevación de pie (m)	0,22 $\pm$ 0,00 [0.22–0.22]	0,25 $\pm$ 0,00 [0.25–0.25]	0,12 $\pm$ 0,00 [0.12–0.12]
Alt. tobillo izq. (m)	0,063 $\pm$ 0,008 [0.053–0.081]	0,073 $\pm$ 0,005 [0.065–0.083]	0,044 $\pm$ 0,003 [0.039–0.049]
Alt. tobillo dcho. (m)	0,060 $\pm$ 0,005 [0.054–0.077]	0,073 $\pm$ 0,005 [0.066–0.084]	0,037 $\pm$ 0,004 [0.032–0.047]

4.2. Validación preliminar en el robot real

Como prueba de concepto de la cadena completa con el dispositivo real —interpretación, validación y ejecución—, un operador colaborador del Hospital Infantil Universitario Niño Jesús (HNJ) en Madrid operó la arquitectura propuesta sobre el robot real utilizando comandos por voz y el modelo *gemin-2.5-flash-lite*. Por seguridad, las pruebas se realizaron sin ningún sujeto en la plataforma. A través de cinco órdenes consecutivas en lenguaje natural por voz: inicio del movimiento, un aumento de velocidad de marcha, un incremento y posterior reducción de la longitud de paso, y un ajuste del soporte de peso (Figura 4).

En estas cinco interacciones, el agente generó planes ejecutables y sintácticamente válidos en el 100 % de los casos, cada uno compuesto por una única acción del catálogo. La latencia extremo a extremo del LLM fue de $6,45 \pm 0,26$ s, mientras que la latencia de ejecución ROS posterior a la validación presentó una mediana de 84 ms. Las consignas se reflejaron directamente en las variables del robot: la velocidad medida pasó de 0 a 0.10 m/s en el inicio de la marcha y posteriormente de 0.10 a 0.20 m/s; la amplitud longitudinal de la referencia

del tobillo aumentó de 25 cm a 30 cm y después descendió de 30 cm a 20 cm; y el ajuste de soporte de peso modificó la referencia vertical del módulo pélvico de 25.0 a 50.0 N, con una respuesta medida de 22.2 a 51.3 N para una masa corporal de referencia configurada de 17 kg.

5. Conclusiones

El uso de las plataformas de rehabilitación requiere manipular parámetros de control de bajo nivel, una exigencia que distintos trabajos identifican como barrera de usabilidad y adopción. En este trabajo se ha propuesto una arquitectura que aprovecha la capacidad de contextualización de los LLM y separa la interpretación, de naturaleza probabilística, de la garantía de seguridad: el modelo interpreta la intención del clínico y propone acciones acordes a ella, y una capa determinista las valida contra un catálogo explícito de rangos admisibles antes de ejecutarlas.

La arquitectura se ha implementado sobre la plataforma Discover2Walk y se ha probado en simulación, bajo distintos estilos de interacción, y de forma preliminar sobre el robot real. En simulación se observa un comportamiento próximo al determinista ante órdenes numéricas y una mayor dispersión ante lenguaje clínico cualitativo; en este segundo caso el agente tiende a conservar la dirección terapéutica solicitada, aunque los valores concretos varían entre ensayos. Esta dispersión podría reflejar la propia ambigüedad del lenguaje más que un fallo del sistema, si bien el número de ensayos no permite afirmarlo con seguridad. También en simulación, ninguna de las solicitudes fuera de rango o clínicamente incompatibles llegó a ejecutarse. La prueba sobre el robot real, sin paciente y con un número reducido de órdenes, confirma que la cadena completa funciona sobre el hardware.

Aunque se trata de ensayos preliminares, este trabajo muestra que es viable un control semántico de la plataforma D2W basado en LLM, en el que la intención clínica se traduce en consignas validadas sobre el robot. El trabajo futuro apunta en tres direcciones. La primera es ampliar la validación y la variedad de las interacciones para delimitar mejor hasta dónde el lenguaje clínico resulta ambiguo, así como realizar estudios con personal clínico que permitan evaluar el uso de la interfaz en escenarios reales de rehabilitación y optimizar su integración en los flujos de trabajo asistenciales. La segunda es dotar al agente de conocimiento específico de la tarea mediante recuperación aumentada (RAG), de modo que sus decisiones se apoyen en evidencia clínica y no solo en el catálogo. La tercera, y más ambiciosa, es incorporar realimentación —del propio agente y de los datos que la plataforma genera en tiempo real— para pasar de un sistema de interpretación y ejecución a uno deliberativo: un grafo de comunicación entre el clínico y varios agentes capaces de razonar sobre el contexto y el estado del robot, advertir de problemas detectados y sugerir ajustes de la terapia.

Agradecimientos

Este trabajo ha sido financiado mediante una subvención de Google.org concedida a la Fundación General CSIC. Google.org no ha intervenido en el diseño, la ejecución, el análisis




Figura 4: Validación sobre el robot D2W real. Secuencia de cinco órdenes en lenguaje natural emitidas por el operador (1–5), cada una interpretada por el agente como una llamada a una acción del catálogo y aplicada sobre la plataforma. Las gráficas muestran la respuesta del robot —referencia frente a señal medida— en torno a cada interacción, indicada mediante una línea discontinua: velocidad de marcha (1, 2), trayectoria del tobillo derecho en el eje X, cuya amplitud refleja la longitud de paso (3, 4), y fuerza vertical asociada al módulo de soporte de peso (5). El eje temporal corresponde al tiempo transcurrido desde el inicio de la sesión.

ni la difusión de esta investigación, ni en las decisiones relativas a su publicación o presentación. Este trabajo está dedicado a la memoria de Manuel Cebrián, cuya visión y dedicación fueron esenciales para esta investigación.

Referencias

- Chen, W. et al., 2025. Llm-enabled incremental learning framework for hand exoskeleton control. *IEEE Transactions on Automation Science and Engineering* 22, 2617–2626. DOI: 10.1109/TASE.2024.3382679
- Dries, D. et al., 2023. PaLM-E: An embodied multimodal language model. In: *Proceedings of the 40th International Conference on Machine Learning*. Vol. 202 of *Proceedings of Machine Learning Research*. PMLR, pp. 8469–8488. DOI: 10.5555/3618408.3618748
- Emken, J. L. et al., 2005. Robot-enhanced motor learning: Accelerating internal model formation during locomotion by transient dynamic amplification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 13 (1), 33–39. DOI: 10.1109/TNSRE.2004.843173
- Huang, W. et al., 2023a. VoxPoser: Composable 3D value maps for robotic manipulation with language models. In: Tan, J. et al. (Eds.), *Proceedings of The 7th Conference on Robot Learning*. Vol. 229 of *Proceedings of Machine Learning Research*. PMLR, pp. 540–562. URL: <https://proceedings.mlr.press/v229/huang23b.html>
- Huang, W. et al., 2023b. Inner monologue: Embodied reasoning through planning with language models. In: *Proceedings of the 6th Conference on Robot Learning*. Vol. 205 of *Proceedings of Machine Learning Research*. PMLR, pp. 1769–1782.
- Ichter, B. et al., 2023. Do as i can, not as i say: Grounding language in robotic affordances. In: *Proceedings of the 6th Conference on Robot Learning*. Vol. 205 of *Proceedings of Machine Learning Research*. PMLR, pp. 287–318.
- Kim, E. et al., 2025. Clinician-directed large language model software generation for therapeutic interventions in physical rehabilitation. DOI: 10.48550/arXiv.2511.18274.
- Klaic, M. et al., 2024. Application of the extended technology acceptance model to explore clinician likelihood to use robotics in rehabilitation. *Disability and Rehabilitation: Assistive Technology* 19 (1), 52–59. DOI: 10.1080/17483107.2022.2060356
- Liang, J. et al., 2023. Code as policies: Language model programs for embodied control. In: *2023 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, pp. 9493–9500. DOI: 10.1109/ICRA48891.2023.10160591
- Marchal-Crespo, L. et al., 2009. Review of control strategies for robotic movement training after neurologic injury. *Journal of NeuroEngineering and Rehabilitation* 6, 20. DOI: 10.1186/1743-0003-6-20
- Meyer, J. T. et al., 2021. An analysis of usability evaluation practices and contexts of use in wearable robotics. *Journal of NeuroEngineering and Rehabilitation* 18 (1), 170. DOI: 10.1186/s12984-021-00963-8
- Nicora, G. et al., 2025. Healthcare practitioners and robotic-assisted rehabilitation: Understanding needs and barriers. *Journal of NeuroEngineering and Rehabilitation* 22, 78. DOI: 10.1186/s12984-025-01593-0
- Romero-Sorozábal, P. et al., 2024. Discover2walk: A cable-driven robotic platform to promote gait in pediatric population. In: *2024 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. pp. 4678–4685. DOI: 10.1109/IROS58592.2024.10802838
- Schick, T. et al., 2023. Toolformer: Language models can teach themselves to use tools. In: *Advances in Neural Information Processing Systems*. Vol. 36. pp. 68539–68551. DOI: 10.52202/075280-2997
- Singhal, K. et al., 2023. Large language models encode clinical knowledge. *Nature* 620 (7972), 172–180. DOI: 10.1038/s41586-023-06291-2
- van Dellen, F. et al., 2022. Settings matter: A scoping review on parameters in robot-assisted gait therapy identifies the importance of reporting standards. *Journal of NeuroEngineering and Rehabilitation* 19, 40. DOI: 10.1186/s12984-022-01017-3
- Varela, I. D. et al., 2026. Poirot: Interrogating agents for failure detection in multi-agent systems. DOI: 10.48550/arXiv.2606.02282.
- Xia, Y. et al., 2025. Control industrial automation system with large language model agents. In: *2025 IEEE 30th International Conference on Emerging Technologies and Factory Automation (ETFA)*. pp. 1–8. DOI: 10.1109/ETFA65518.2025.11205539
- Yao, S. et al., 2023. React: Synergizing reasoning and acting in language models. In: *International Conference on Learning Representations*.
- Zitkovich, B. et al., 2023. Rt-2: Vision-language-action models transfer web knowledge to robotic control. In: *Proceedings of the 7th Conference on Robot Learning*. Vol. 229 of *Proceedings of Machine Learning Research*. PMLR, pp. 2165–2183.