

Evaluación cuantitativa de la afectación motora mediante un dispositivo robótico de rehabilitación

Martín-Batanero, R.^{a,*}, Vales, Y.^a, Rubira-Úbeda, P.^a, Peral-Sempere, E.^a, Martínez-Pascual, D.^a, García-Aracil, N.^a

^aGrupo de investigación de Robótica e Inteligencia Artificial del Instituto de Bioingeniería, Universidad Miguel Hernández, Avda. de la Universidad, 03202, Elche, España.

Resumen

Este trabajo presenta un estudio inicial para el desarrollo de un sistema de evaluación motora del miembro superior basado en métricas cuantitativas obtenidas mediante un dispositivo robótico de rehabilitación. El objetivo es alcanzar evaluaciones objetivas y reproducibles que complementen las escalas clínicas tradicionales en pacientes con afectación motora derivada de lesiones neurológicas. Para ello, se registraron datos de movimiento y asistencia durante la realización de una tarea guiada, extrayéndose métricas cuantitativas. Posteriormente, se analizaron sus correlaciones con la escala Fugl-Meyer y se emplearon como entrada para entrenar modelos de aprendizaje automático orientados a clasificar el nivel de afectación motora en tres categorías. Los resultados muestran que métricas, como las relacionadas con la velocidad y la asistencia proporcionada por el robot, presentan un mayor poder discriminativo. Aunque el rendimiento de los modelos fue limitado, los hallazgos permiten identificar métricas prometedoras y plantean la necesidad de ajustar las tareas de evaluación para reflejar mejor la capacidad real del paciente.

Palabras clave: Tecnología de asistencia e ingeniería de rehabilitación, Ingeniería de rehabilitación y prestación de asistencia sanitaria, Identificación y validación, Análisis e interpretación de señales biológicas, Avances en medición y procesamiento de señales.

Quantitative assessment of motor impairment using a robotic rehabilitation device

Abstract

This paper presents an initial study for the development of an upper limb motor assessment system based on quantitative metrics obtained using a rehabilitation device. The aim is to achieve objective and reproducible assessments that complement traditional clinical scales in patients with motor impairment resulting from neurological injuries. To this end, movement and assistance data were recorded during the performance of a guided task, and quantitative metrics were extracted. Subsequently, their correlations with the Fugl-Meyer scale were analyzed and used as input to train machine learning models aimed at classifying the level of motor impairment into three categories. The results show that metrics such as those related to speed and assistance provided by the robot have greater discriminatory power. Although the performance of the models was limited, the findings identify promising metrics and highlight the need to adjust assessment tasks to better reflect the patient's actual ability.

Keywords: Assistive technology and rehabilitation engineering, Rehabilitation engineering and healthcare provision, Identification and validation, Analysis and interpretation of biological signals, Advances in signal measurement and processing.

1. Introducción

La hemiparesia del miembro superior es una de las secuelas más frecuentes tras un accidente cerebrovascular, afectando de manera significativa la capacidad funcional y a la autonomía de de las personas afectadas (Gorelick, 2019). La recuperación motora requiere intervenciones terapéuticas

intensivas, repetitivas y adaptativas, que permitan no solo favorecer la neuroplasticidad, sino también cuantificar con precisión el progreso funcional. En este contexto, la robótica aplicada a la rehabilitación se ha consolidado como una de las herramientas más prometedoras tanto para la terapia como para la evaluación objetiva del movimiento .

*Autor para correspondencia: raul.martin@umh.es

Diversos estudios recientes han destacado el potencial de los dispositivos robóticos para capturar métricas sobre cinemática y dinámica, permitiendo así una caracterización detallada del desempeño motor, los cuales difícilmente se pueden obtener con métodos clínicos tradicionales. Por ejemplo, (García-Silva et al., 2025) demostraron que la combinación de análisis cinemático y EMG durante la terapia robótica permite cuantificar mejoras en fuerza, rango de movimiento y precisión del movimiento en pacientes con afectación neurológica, proporcionando una alternativa robusta a las evaluaciones subjetivas convencionales. Del mismo modo, estudios en telerehabilitación con robots como el sistema H-Man (Aguirre-Ollinger et al., 2024) han demostrado que, además de facilitar el tratamiento en entornos domésticos, estos dispositivos permiten obtener mediciones objetivas de escalas estandarizadas como Fugl-Meyer y ARAT, evidenciando cambios funcionales medibles a lo largo del tiempo en personas con hemiparesia post-ictus. A su vez, estudios que abordan la combinación de robótica con realidad virtual (Tutak and Mucha, 2025) han mostrado mejoras tanto en parámetros objetivos (velocidad, tiempo, trayectoria) como en resultados clínicos tradicionales, reforzando el valor de estos sistemas para la evaluación. Por otro lado, recientes revisiones sistemáticas también respaldan el uso de la robótica para mejorar la función motora, pero además, que proporciona un entorno cuantitativo ideal para desarrollar evaluaciones. La revisión de (Thawisuk et al., 2025) destacó que tanto el uso independiente como combinado del dispositivo permite registrar parámetros cuantificables del rendimiento motor, ofreciendo evidencia sólida sobre su utilidad para monitorizar la evolución clínica y reforzando el potencial de la robótica como herramienta de evaluación sistemática en pacientes con secuelas post-ictus. En el trabajo de (Wang et al., 2025) revisaron los avances en robots de rehabilitación de miembro superior y remarcaron su creciente papel en aplicaciones clínicas, señalando mejoras constantes en mecanismos, control y personalización de terapias, así como el potencial de integrar técnicas de inteligencia artificial para optimizar la evaluación cuantitativa del movimiento.

En conjunto, la evidencia actual apunta a que los dispositivos robóticos son una herramienta clave para la evaluación objetiva, precisa y reproducible del movimiento en pacientes con afectación motora en el miembro superior. Esto abre las posibilidades del desarrollo de protocolos de evaluación más completos, basados en datos cuantitativos, esencial para la toma de decisiones clínicas.

En este artículo se presenta un estudio inicial que tiene como objetivo desarrollar un sistema de evaluación motora a partir de parámetros cuantitativos obtenidos mediante un dispositivo robótico de rehabilitación de miembro superior haciendo uso de modelos de Machine Learning (ML).

2. Materiales y métodos

2.1. Dispositivo de rehabilitación de miembro superior

En este estudio, se utilizó el dispositivo robótico de rehabilitación de miembro superior denominado Rubidium (Figura 1) comercializado y distribuido por la spin-off iDRhA (iDRhA, 2019). Este es un dispositivo de rehabilitación portable

que consiste en un mecanismo tipo paralelogramo articulado que es actuado por dos motores eléctricos para actuar en el plano horizontal. Los pacientes colocan su antebrazo sobre una órtesis anclada al efector final del mismo, pudiendo así soportar todo el peso del brazo.



Figura 1: Dispositivo robótico de rehabilitación de miembro superior Rubidium comercializado y distribuido por iDRhA.

2.2. Participantes

El estudio se llevó a cabo en el Hospital IMED Internacional Center y el Hospital de La Pedrera (Alicante, España) con pacientes que acudían a la unidad de neurorrehabilitación para recuperar la función motora de su miembro superior tras sufrir una lesión neurológica. El estudio fue aprobado por el comité de ética (registro HLP-99-2023). Todos los participantes firmaron un consentimiento informado tras recibir la información correspondiente.

Los criterios de inclusión establecidos fueron: 1) adultos diagnosticados con una lesión neurológica 2) presentación de afectación motora en al menos uno de los miembros superiores (> 20 puntos en la escala Fugl-Meyer) 3) capacidad de agarre. Los criterios de exclusión incluyeron 1) espasticidad severa (> 3 puntos en la Escala Modificada de Ashworth), 2) dolor en el miembro superior, 3) control insuficiente del tronco para mantener la posición de sedestación durante las tareas 4) alteraciones visuales.

El estudio ha contado con la participación de 44 usuarios con daño cerebral adquirido. Los pacientes fueron evaluados con la escala Fugl-Meyer (FMA) de miembro superior, cuya media y desviación estándar es de $27,17 \pm 22,73$. Partiendo de la valoración realizada, se clasificó a los participantes en tres grupos: deterioro leve (>50 puntos), deterioro moderado (20-50 puntos) y deterioro severo (< 20 puntos).

2.3. Protocolo

Durante el estudio se empleará la actividad representada en la Figura 2 usando el dispositivo Rubidium. El objetivo de la actividad es completar la ruleta moviendo el cursor, representado de color blanco, desde el punto central al punto de la periferia marcado en una tonalidad naranja. Cada objetivo debe alcanzarse en un tiempo determinado. El proceso se repite hasta alcanzar 30 objetivos, dando por finalizada la actividad.

Cabe destacar que, debido al deterioro motor en el miembro afectado, existen pacientes que no son capaces de realizar

por ellos mismos la actividad. Como apoyo, el dispositivo Rubidium tiene incorporado un método de asistencia basado en campos de potencial (Vales et al., 2022), (Catalán et al., 2021) capaces de:

- Guiar al paciente para realizar una trayectoria rectilínea desde el punto central al objetivo, similar a un túnel que el paciente puede atravesar libremente.
- Ofrecer asistencia al movimiento cuando el paciente no pueda llegar al objetivo. En concreto, el robot ejerce la fuerza necesaria para llevar el miembro del usuario al punto objetivo.

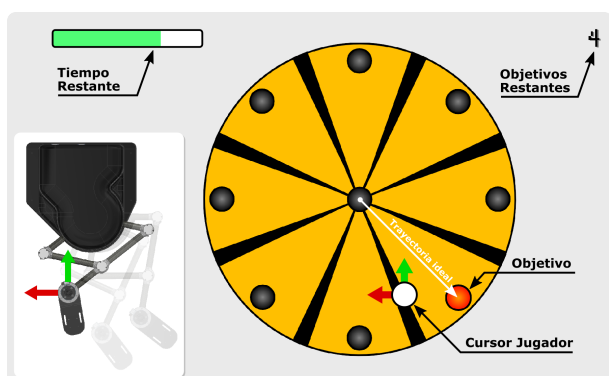


Figura 2: Actividad empleada para la evaluación motora con dispositivo Rubidium durante el estudio inicial.

2.4. Métricas Evaluadas

Mediante el robot se recogen métricas de posición, velocidad y fuerza ejercida sobre el efector final. Además, se recogen datos sobre el rendimiento del usuario durante el juego. Para realizar la evaluación, partiendo de los datos recogidos mediante el robot, se han extraído una serie de métricas durante la realización de la actividad:

- **Porcentaje de éxito (%)**. Objetivos alcanzados dentro del tiempo máximo.
- **Error de trayectoria (cm)**. Error de seguimiento con respecto a la trayectoria rectilínea ideal.
- **Ángulo de salida (°)**. Ángulo inicial de la trayectoria realizada por el usuario con respecto a la trayectoria rectilínea ideal.
- **Velocidad media (m/s)**. Valor medio de la velocidad durante el juego.
- **Velocidad RMS (m/s)**. Valor RMS de la velocidad durante el juego.
- **Velocidad máxima (m/s)**. Velocidad máxima durante el juego.
- **Media de tiempo de reacción (s)**. Media de tiempo que tarda el usuario en comenzar el movimiento desde que se ilumina el objetivo.
- **Valor RMS de tiempo de reacción (s)**. Tiempo RMS de reacción que tarda en comenzar el movimiento.

- **Tiempo máximo (s)**. Tiempo de reacción máximo en que se tarda en comenzar el movimiento.
- **Valor medio de fuerza y asistencia (N)**. Fuerza media realizada por el robot durante la actividad.
- **Valor RMS de fuerza de asistencia (N)**. Fuerza RMS realizada por el robot durante la actividad.
- **Porcentaje de tiempo de asistencia (%)**. Porcentaje del tiempo durante la actividad que el robot realiza asistencia al usuario.

2.5. Análisis de datos

Partiendo de las métricas extraídas se ha realizado un análisis exploratorio de los datos para evaluar qué métricas puedan tener un mayor peso en la estimación de la afectación motora de los usuarios.

En primer lugar se ha analizado la normalidad del conjunto de datos para cada métrica mediante el test de Shapiro-Wilk, dando como resultado una distribución no normal ($p > 0,05$, en todos los casos). Partiendo de este análisis, se evaluaron diferencias entre grupos mediante el test de Kruskal-Wallis y posteriormente se realizó una comparación por pares mediante el test de Mann-Whitney.

Además, se ha analizado la correlación de cada métrica con la puntuación de la escala FMA-UE mediante el coeficiente de correlación de Spearman.

2.6. Selección de Algoritmos de Machine Learning

Para clasificar la afectación entre leve, moderada y grave el problema puede interpretarse como una tarea clásica de clasificación multiclase, donde el modelo infiere con una cierta probabilidad entre 0 y 1 la pertenencia a cada clase. Para abordar el problema de la toma de decisión, se ha valorado emplear diferentes algoritmos de ML, los cuales se detallan a continuación: 1) *Bosques aleatorios o Random Forests*. Se trata un algoritmo que emplea un conjunto de árboles de decisión para realizar una clasificación. De forma general son muy precisos y menos propensos al sobreaprendizaje. Aunque son potentes, son menos interpretables que los árboles de decisión y requieren métodos de interpretabilidad post-hoc. 2) *XGBoost (eXtreme Gradient Boosting)*. Es una versión avanzada y optimizada de las Máquinas de Potenciación del Gradiente (GBMs). Su funcionamiento se basa en la creación secuencial de un modelo predictivo robusto a partir de una serie de modelos “débiles”, que son típicamente árboles de decisión. El proceso es iterativo: el primer árbol realiza una predicción inicial, y cada árbol subsiguiente se entrena específicamente para corregir los errores residuales que han dejado todos los modelos anteriores. Para lograr esto, XGBoost utiliza un enfoque basado en el gradiente para encontrar la dirección más eficiente para minimizar la función de pérdida (o error) del conjunto. Este mecanismo de “boosting” asegura que el modelo aprenda continuamente de sus fallos, permitiéndole alcanzar una alta precisión tanto en problemas de clasificación como de regresión, convirtiéndolo en una herramienta muy potente y eficiente en el análisis predictivo. 3) *Máquinas de vector soporte o Support Vector Machines (SVM)*. Son algoritmos que se centra en la clasificación al encontrar el hiperplano óptimo que maximiza el margen de separación entre las distintas clases

de datos. Este margen se define por los puntos de datos más cercanos al hiperplano, conocidos como vectores de soporte. Para manejar datos que no son linealmente separables, las SVM emplean un kernel, que mapea implícitamente los datos a un espacio de mayor dimensión donde pueden ser separados linealmente, lo que las convierte en una herramienta versátil y poderosa para la clasificación.

2.7. Entrenamiento y Evaluación de los Modelos de Machine Learning

Esta etapa del proceso implica la selección de un algoritmo de ML apropiado, así como la optimización de sus parámetros para adaptarse a los datos recabados. El objetivo principal de este proceso es aprender patrones a partir de datos etiquetados para realizar predicciones sobre los datos recabados de nuevos pacientes.

Con el objetivo de garantizar la generalización del modelo y evitar el sobreaprendizaje, resulta primordial dividir el conjunto de datos de los que se dispone en tres subconjuntos: entrenamiento, validación y test. Además, cabe destacar que es de vital importancia dividir los datos a nivel de paciente, especialmente cuando se obtienen múltiples registros de los mismos pacientes. Esto asegura la independencia entre los conjuntos de datos, evitando que el modelo disponga de datos de un paciente durante el entrenamiento y su evaluación, pudiendo resultar en estimaciones de rendimiento optimistas.

Para evaluar los modelos se empleará la precisión como métrica principal de evaluación. Además, la evaluación de los modelos entrenados se realizará mediante validación cruzada empleando los diferentes conjuntos de datos de la siguiente forma:

- Conjuntos de entrenamiento y validación (70 %). El conjunto de datos de entrenamiento se empleará para ajustar los hiperparámetros de los modelos de ML seleccionados. A su vez, se comprueba si existe un sobreajuste del modelo con el conjunto de datos de validación. Dentro de este grupo de pacientes se empleará el 80 % de los datos como conjunto de entrenamiento y el 20 % restante como validación.
- Conjunto de test (30 %). Este conjunto de datos se emplea para validar el rendimiento final del modelo una vez ajustados los hiperparámetros.

Asimismo, previo al entrenamiento se ha realizado un escalado de cada característica de entrada entre su mínimo y máximo. De esta forma, todos los valores del vector de entrada estarán comprendidos en el rango [0,1]. Así, se evita que una de las características domine sobre el resto debido a su elevada o reducida magnitud en comparación con el resto de entradas.

3. Resultados y discusiones

3.1. Análisis exploratorio

Los resultados recogidos en la Tabla 1 revelan una variedad en la magnitud de la correlación de las métricas empleadas con la puntuación obtenida en la FMA para la evaluación de la afectación motora.

Se observa una correlación positiva fuerte de la FMA con la velocidad media (0.63) y la RMS (0.64), y también existe una correlación moderada con la velocidad máxima (0.59). Además, existe una correlación positiva fuerte de la FMA con el porcentaje de éxito. Este patrón sugiere que un aumento en la velocidad de ejecución (media, RMS o máxima) y una mejor habilidad para alcanzar los objetivos se asocia con una mayor puntuación en la FMA, lo que indica una mejor función motora.

Por otra parte, se encuentra una correlación negativa fuerte en el porcentaje de tiempo asistencia (-0.69) y una correlación negativa moderada con la media de fuerza de asistencia (-0.57). Estas correlaciones implican que un mayor porcentaje de tiempo o fuerza de asistencia durante la tarea se relaciona con una menor puntuación en la FMA, lo que indica una peor función motora.

Tabla 1: Correlación de las métricas con la puntuación de afectación motora obtenida mediante la escala FMA-UE.

Métrica	Correlación	p-value
Porcentaje de éxito	0.59	<0.0001
Error de trayectoria	0.31	0.0007
Ángulo de salida	0.11	0.2574
Media velocidad	0.63	<0.0001
RMS velocidad	0.64	<0.0001
Velocidad máxima	0.59	<0.0001
Media tiempo reacción	-0.34	0.0002
RMS tiempo reacción	-0.39	<0.0001
Media fuerza asistencia	-0.57	<0.0001
RMS fuerza asistencia	-0.48	<0.0001
Porcentaje tiempo asistencia	-0.69	<0.0001

La distribución de las métricas empleadas se ha representado en la Figura 3. El análisis de comparaciones por pares entre los grupos (Tabla 2) mostró diferencias significativas en la mayoría de las métricas evaluadas. En las variables asociadas a la velocidad y porcentaje de éxito se observaron diferencias estadísticamente significativas en todas las comparaciones ($p < 0,01$).

Tanto el error medio de trayectoria como el tiempo de reacción (media y RMS) mostraron diferencias entre grupo leve y los grupos moderado y grave ($p < 0,05$). Sin embargo, no se identificaron diferencias significativas entre los grupos moderado y grave en estas métricas ($p > 0,13$).

Las métricas relacionadas con la asistencia, mostraron tanto en su valor medio como RMS, que no se detectaron diferencias significativas entre los grupos leve y moderado ($p = 0,1481$ y $p = 0,4117$, respectivamente). No obstante, sí se identificaron diferencias significativas entre los grupos leve-grave y moderado-grave ($p < 0,001$).

La Velocidad media, la Velocidad RMS y la Velocidad máxima muestran un aumento progresivo en sus medianas y rangos intercuartílicos a medida que la afectación motora se reduce. Los pacientes con afectación leve no solo alcanzan velocidades máximas más altas, sino que mantienen una velocidad promedio y RMS superiores. De igual forma, el porcentaje de éxito también aumenta, con el grupo leve alcanzando tasas significativamente más altas, lo que indica una mejor ejecución global de la tarea.

Tabla 2: Comparación por pares de los grupos.

Métrica	Leve - Moderado	Leve - Grave	Moderado - Grave
Porcentaje de éxito	0.0040	<0.0001	0.0017
Error de trayectoria	0.0445	0.0093	0.1304
Media velocidad	0.0024	<0.0001	<0.0001
RMS velocidad	0.0018	<0.0001	<0.0001
Velocidad máxima	0.0070	<0.0001	<0.0001
Media tiempo reacción	0.0229	0.0026	0.3354
RMS tiempo reacción	0.0207	0.0011	0.1537
Media fuerza asistencia	0.1481	<0.0001	0.0001
RMS fuerza asistencia	0.4117	<0.0001	0.0004
Porcentaje tiempo asistencia	0.0064	<0.0001	<0.0001

Las métricas de asistencia y tiempo de reacción también son buenos discriminadores. Tanto la Fuerza de asistencia media, la Fuerza de asistencia RMS, como el Tiempo de asistencia muestran una disminución en sus medianas a través de los grupos. Los pacientes leves requieren una asistencia significativamente menor y durante un menor porcentaje de tiempo, lo que se traduce en una mayor autonomía motora. En cuanto al tiempo, el Tiempo de reacción medio y el Tiempo de reacción RMS también disminuyen de forma constante, lo que indica que el grupo leve responde más rápidamente y de forma más consistente.

3.2. Evaluación de los modelos de Machine Learning Entrenados

En la Tabla 3 se recogen los resultados de evaluación de los modelos de ML entrenados. De acuerdo con los resultados, solo el modelo Random Forest es capaz de alcanzar una precisión de clasificación mayor al 50% con el conjunto de validación el grado de afectación motora de los participantes (57,1%). Sin embargo, puede observarse cómo el rendimiento de este modelo se ve reducido al ser evaluado con el conjunto de test (47,6%).

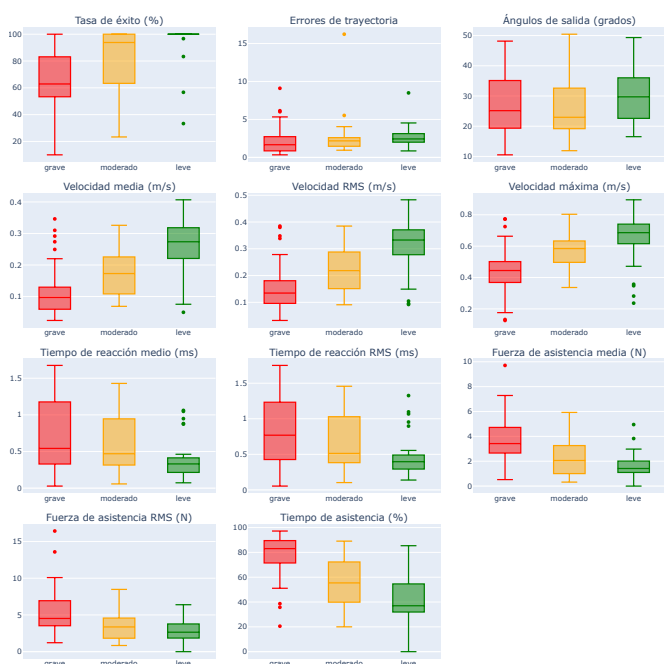


Figura 3: Distribución de las métricas empleadas según el grado de afectación motora.

En base a este análisis exploratorio, se han seleccionado 4 características de entre el grupo de métricas con mayor correlación con la puntuación obtenida mediante la FMA y mayor diferencia en las distribuciones ente grupos. Se han seleccionado la velocidad media, el tiempo de reacción medio, la media de la fuerza de asistencia y el porcentaje de asistencia durante la actividad.

Tabla 3: Precisión obtenida con los modelos de ML entrenados.

Modelo	Precisión (Validación)	Precisión (Test)
XGBoost	38.8	33.3
Random Forest	57.1	47.6
SVM	40.7	36.0

Debido a este bajo rendimiento, se ha realizado un análisis exhaustivo acerca de las clasificaciones incorrectas realizadas por el modelo. Es decir, se analizan los casos dónde la evaluación de la FMA no coincide con la inferida por el modelo. Un análisis inicial revela que el 70.6% de las clasificaciones erróneas califica a los pacientes con una afectación motora superior que la dictada por la FMA.

En base a este análisis inicial, en la Figura 4 muestra dos ejemplos de pacientes cuya afectación motora fue clasificada por el modelo Random Forest de forma incorrecta. En concreto, ambos pacientes poseen un grado de afectación motora moderado, pero fueron clasificados como leves. De acuerdo con los resultados representados, puede verse como las métricas obtenidas para ambos pacientes (línea de puntos) es superior a su grupo. Por tanto, la causa más plausible a estos errores de clasificación recae en que los pacientes tienen un rendimiento equivalente al grupo de afectación motora leve. Una de las posibles hipótesis a este comportamiento radica en que dispositivo Rubidium permite descargar el peso del miembro superior, algo que no ocurre durante la evaluación de la FMA. Por tanto, estos resultados sugieren que la evaluación de la capacidad motora del miembro superior mediante dispositivos robóticos debe ser contextualizada con dispositivos o evaluaciones adicionales.

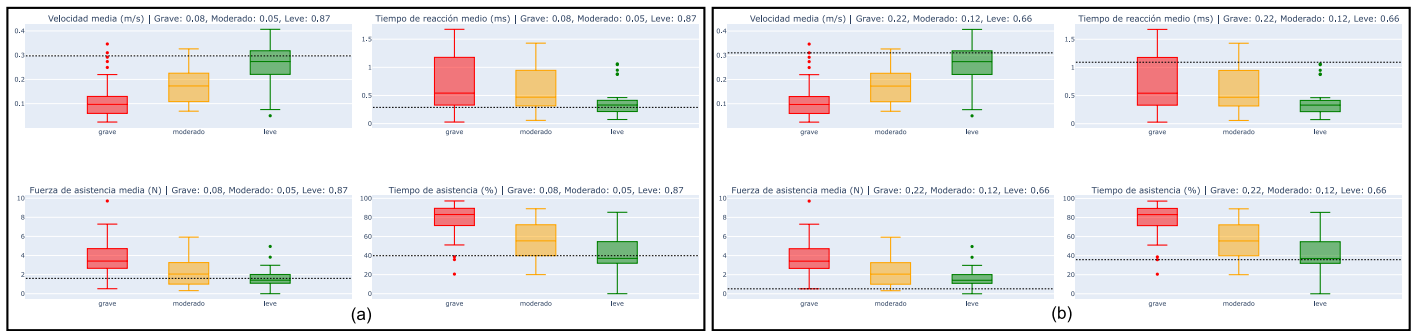


Figura 4: Ejemplos de clasificación de grado de afectación motora incorrectas para dos pacientes. Ambos pacientes son moderados según la FMA, pero fueron clasificados como leves por el modelo RF. La línea de puntos representa el valor de la métrica para dicho paciente, la cual ha sido representada sobre la distribución de los tres grupos para aportar contexto.

4. Conclusiones

En este estudio inicial se ha tratado de evaluar el grado de afectación motora mediante uno de los ejercicios incluidos con el robot Rubidium. A partir de los datos recogidos mediante el robot, se ha analizado la correlación de diversas métricas con la puntuación de la FMA. Mediante este análisis se seleccionaron algunas métricas debido a la diferencia existente entre grupos y su correlación con dicha escala, empleando estos datos para entrenar un modelo de ML que sea capaz de predecir el grado de afectación motora. Los resultados de clasificación obtenidos muestran que el 70,6 % de las clasificaciones erróneas etiquetan a los pacientes con un control mayor que el evaluado mediante la FMA. Esto se debe a que las métricas empleadas muestran que dichos usuarios se comportan como leves durante la actividad en lugar de como el grupo moderado. La principal hipótesis de este comportamiento es que el robot sujeta el peso del brazo del usuario, mostrando una evaluación con mayor capacidad motora respecto a las escalas tradicionales.

A la vista de los resultados, se propone modificar la actividad propuesta para la evaluación motora de pacientes con el robot Rubidium con dispositivos y métricas adicionales. Además, se pretende ampliar el número de usuarios involucrados para tener una mayor base de datos con las que comparar diferencias entre grupos de pacientes, así como para entrenar y evaluar los modelos de ML.

Agradecimientos

Este trabajo ha sido financiado parcialmente por Agencia Estatal de Investigación, la Unión Europea-Next Generation EU y Generalitat Valenciana a través de los

proyectos CIPROM/2022/12, PID2022-139957OB-I00 y CPP2023-010685.

Referencias

- Aguirre-Ollinger, G., Chua, K. S. G., Ong, P. L., Kuah, C. W. K., Plunkett, T. K., Ng, C. Y., Khin, L. W., Goh, K. H., Chong, W. B., Low, J. A. M., et al., 2024. Telerehabilitation using a 2-d planar arm rehabilitation robot for hemiparetic stroke: a feasibility study of clinic-to-home exergaming therapy. *Journal of NeuroEngineering and Rehabilitation* 21 (1), 207.
- Catalán, J. M., García-Pérez, J. V., Blanco, A., Ezquerro, S., Garrote, A., Costa, T., Bertomeu-Motos, A., Díaz, I., García-Aracil, N., 2021. Tele-rehabilitation versus local rehabilitation therapies assisted by robotic devices: A pilot study with patients. *Applied Sciences* 11 (14). URL: <https://www.mdpi.com/2076-3417/11/14/6259> DOI: 10.3390/app11146259
- García-Silva, J., Mendoza-Gutiérrez, M. O., Bonilla-Gutiérrez, I., Reyes, B. A., 2025. Case study on robotic-assisted therapy: kinematic and emg analysis of upper limb motor recovery in complex trajectory tracking. *International Journal of Intelligent Robotics and Applications*, 1–25.
- Gorelick, P. B., 2019. The global burden of stroke: persistent and disabling. *The Lancet Neurology* 18 (5), 417–418.
- iDRha, 2019. Innovative devices for rehabilitation assistance. URL: <https://www.idrha.es>
- Thawisuk, C., Apichai, S., Chingchit, W., Dhippayom, J. P., Dhippayom, T., 2025. Effectiveness of robot-assisted upper extremity function training (gloreha) on upper extremities function after stroke: Systematic review. *JMIR Rehabilitation and Assistive Technologies* 12 (1), e68268.
- Tutak, J. S., Mucha, J., 2025. A prototype mechatronic device for upper limb rehabilitation and analysis of its functionality. *Applied Sciences* 15 (12), 6613.
- Vales, Y., Catal, J. M., Lled, L. D., Blanco, A., Álvarez-Pastor, J., Martínez-Pascual, D., Garrote, A., Costa, T., Más, G., García-Aracil, N., 2022. Influence of session duration in robot-assisted neurorehabilitation therapies: a pilot study with patients. In: *Iberian Robotics conference*. Springer, pp. 286–297.
- Wang, Y., Han, X., Xin, B., Zhao, P., 2025. Innovations in upper limb rehabilitation robots: A review of mechanisms, optimization, and clinical applications. *Robotics* 14 (6), 81.