

Jornadas de Automática

Sistema de telerehabilitación para evaluar la función motora del miembro superior mediante IMUs y Machine Learning

Martínez-Pascual, David †^{a,*}, Vales, Yolanda †^a, Martín-Batanero, Raúl^a, Rubira-Úbeda, Pablo^a, Catalán, José María^a, Lledó, Luis Daniel^a, García-Aracil, Nicolás^a

^aGrupo de Robótica e Inteligencia Artificial, Instituto de Bioingeniería de Elche, Universidad Miguel Hernández,

Avenida de la Universidad, s/n. 03202 Elche, Alicante, España

To cite this article: Martínez-Pascual, David, Vales, Yolanda, Martín-Batanero, Raúl, Rubira-Úbeda, Pablo, Catalán, José María, Lledó, Luis Daniel, García-Aracil, Nicolás. 2025. A telerehabilitation system to assess upper limb motor function using IMUs and Machine Learning. *Jornadas de Automática*, 46. <https://doi.org/10.17979/ja-cea.2025.46.12166>

Resumen

Las lesiones neurológicas pueden provocar una discapacidad importante, sobre todo en la función motora de las extremidades superiores, lo que reduce la capacidad de los pacientes para realizar las actividades de la vida diaria (AVD). Con el objetivo de desarrollar un sistema de telerehabilitación que permita evaluar el paciente a distancia se propone un sistema basado en tres unidades magneto-iniciales (IMUs). Estas IMUs capturan trayectorias articulares que luego sirven de entrada para un modelo de Machine Learning (ML) encargado de reconocer doce AVDs. Además, el estudio compara las trayectorias de pacientes con discapacidad motora y usuarios sin discapacidad usando la técnica de Dynamic Time Warping (DTW) para calcular índices de similaridad, lo que puede permitir estimar el nivel de deterioro motor como leve o moderado. La viabilidad del sistema ha sido evaluada con 31 pacientes y 9 usuarios de control, demostrando su efectividad en la identificación de actividades y la evaluación de la función motora.

Palabras clave: Tecnología de asistencia e ingeniería de rehabilitación, Ingeniería de rehabilitación y asistencia sanitaria, Toma de decisiones y procesos cognitivos, Automatización centrada en el ser humano, Interfaces inteligentes

A telerehabilitation system to assess upper limb motor function using IMUs and Machine Learning.

Abstract

Neurological injuries can cause significant disability, especially in the motor function of the upper extremities, causing an impairment in patients' ability to perform activities of daily living (ADL). In order to develop a telerehabilitation system that allows remote patient assessment, a system based on three magneto-inertial units (IMUs) is proposed. These IMUs measure joint trajectories that are used as input for a Machine Learning (ML) model in charge of recognizing twelve ADLs. In addition, this study compares the trajectories of patients with motor disabilities and non-disabled users using the Dynamic Time Warping (DTW) technique to calculate similarity indices. These indices can be used to enable the assessment of impairment levels as mild or moderate. The feasibility of the system has been evaluated with 31 patients and 9 control users, demonstrating its effectiveness in identifying activities and assessing motor function.

Keywords: Assitive technology and rehabilitation engineering, Rehabilitation engineering and healthcare delivery, Decision making and cognitive processes, Human centred automation, Intelligent interfaces

* Autor para correspondencia: david.martinezp@umh.es

† La contribución de estos autores es igual

Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

1. Introducción

El accidente cerebrovascular constituye una de las principales causas de discapacidad a nivel mundial, afectando especialmente a la función motora del miembro superior, cuya recuperación resulta particularmente compleja. En este contexto, la telerehabilitación ha ganado protagonismo como estrategia eficaz para dar continuidad al tratamiento en el entorno domiciliario, facilitando la atención remota y reduciendo la carga asistencial de los centros hospitalarios (Gorelick, 2019; Moulaei et al., 2022).

El proceso de rehabilitación tras un ictus suele ser largo, y el grado de afectación motora varía a medida que avanza la rehabilitación. Por ello, es necesario realizar una evaluación objetiva y cuantitativa del deterioro motor para diseñar intervenciones personalizadas (Steinmetz et al., 2024). El método tradicional para evaluar la función motora son las escalas clínicas, como la evaluación de Fugl-Meyer (FMA). Sin embargo, estas herramientas requieren la presencia de profesionales de la salud, lo que pone de manifiesto la necesidad de integrar nuevas tecnologías que permitan realizar evaluaciones precisas en el hogar dentro del contexto de la telerehabilitación (Wang et al., 2024).

El desarrollo de nuevas tecnologías han permitido avances significativos en la evaluación motora en el hogar, especialmente los sistemas portables, encontrándose entre las tecnologías más utilizadas para la evaluación de los pacientes. Estos dispositivos reducen el tiempo de evaluación, aportan datos objetivos y cuantificables, y en algunos casos permiten evaluaciones en tiempo real durante actividades de la vida diaria (AVDs) Maceira-Elvira et al. (2019).

En este contexto, se han utilizado distintos tipos de sensores para evaluar y reconocer movimientos del miembro superior. Dentro de los más utilizados se encuentran las unidades magneto-inerciales (IMUs). Las IMU, junto con algoritmos de reconstrucción cinemática Bertomeu-Motos et al. (2018), posibilitan un análisis detallado del movimiento humano. Su tamaño reducido, facilidad de colocación y estabilidad los convierten en una opción idónea para realizar evaluaciones funcionales en el hogar con alta calidad de datos Maceira-Elvira et al. (2019); Wang et al. (2024).

No obstante, el seguimiento del movimiento durante las AVDs plantea un desafío particular en pacientes con ictus, cuyos movimientos tienden a ser más lentos, fragmentados y variables que los de sujetos sanos. Una posible solución consiste en utilizar muestras de referencia con las que comparar las trayectorias obtenidas (Wang et al., 2024). Además, uno de los principales retos de los sistemas de evaluación es determinar la calidad de los movimientos realizados, un aspecto que todavía continúa en investigación.

Este estudio presenta un sistema de evaluación motora del miembro superior basado en IMUs, que integra técnicas de alineación temporal y algoritmos de Machine Learning (ML) para la valoración objetiva de la calidad del movimiento. Este estudio se llevó a cabo en un grupo de 40 participantes (31 pacientes con ictus y 9 sujetos control). Mediante la colocación de tres IMUs, se registran las trayectorias angulares del hombro y el codo durante la ejecución de doce actividades basadas en AVDs. Estas trayectorias articulares fueron utilizadas como entrada de un modelo de ML diseñado para identificar la ac-

tividad realizada por el usuario y verificar su correspondencia con la indicada en una plataforma software. Paralelamente, se realizó un análisis de la calidad del movimiento comparando dichas trayectorias con una base de datos de referencia proveniente de personas sin discapacidad (expertos). Esta comparación permitió calcular índices de similaridad, S_i , que proporcionan una medida interpretable de la calidad del patrón de movimiento del paciente.

2. Materiales y métodos

2.1. Población de estudio

El estudio se llevó a cabo en el Hospital IMED International 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 FMA-UE) 3) capacidad de agarre. Los criterios de exclusión incluyeron 1) espasticidad severa (> 3 puntos en la Escala Modificada de Ashworth Bohannon and Smith (1987)), 2) dolor en el miembro superior, 3) control insuficiente del tronco para mantener la posición de sedestación durante las tareas 4) alteraciones visuales.

Los participantes sin alteraciones neurológicas, han sido seleccionados por el equipo de investigación del Instituto de Bioingeniería de la Universidad Miguel Hernández de Elche.

El grado de deterioro de la función motora del miembro superior en los pacientes fue evaluado mediante la escala Fugl-Meyer para el miembro superior (FMA-UE), una herramienta específica para la valoración del daño cerebral. Esta escala permite cuantificar el nivel de afectación motora, con una puntuación máxima de 66 puntos, indicando una movilidad óptima de los miembros superiores (Fugl-Meyer et al., 1975).

Los participantes fueron clasificados en dos grupos según los resultados obtenidos en la escala FMA-UE, siguiendo el criterio empleado en estudios previos (Velozo and Woodbury, 2011; See et al., 2013): deterioro leve (> 50 puntos); moderado (20–50 puntos), y severo (< 20 puntos). En este estudio se excluyó el último grupo, ya que no cumplían con los criterios de inclusión establecidos, tras no presentar la movilidad necesaria para la realización de los ejercicios propuestos.

La Tabla 1 presenta las características de los 40 participantes incluidos en el estudio, clasificados en tres grupos: un grupo control, compuesto por individuos sin alteraciones neurológicas (CONTROL, $n = 9$); un grupo con deterioro motor leve (LEVE, $n = 22$); y un grupo con deterioro motor moderado (MODERADO, $n = 9$).

Tabla 1: Datos de los participantes del estudio (n=40).

| | CONTROL | LEVE | MODERADO | p-valor ¹ |
|--------------------|-----------------|---------------|---------------|----------------------|
| n | 9 | 22 | 9 | |
| Hombres | 7 | 8 | 5 | |
| Mujeres | 2 | 14 | 4 | |
| Edad | 30.55 ± 3.43 | 66.45 ± 13.51 | 59.22 ± 16.31 | |
| FM-UE ² | NA ³ | 64.63 ± 2.61 | 31 ± 10.82 | > 0.001 |

Características del grupo control (CONTROL), del grupo con deterioro motor leve (LEVE),y del grupo con deterioro motor moderado (MODERADO). ¹p-Valor. Diferencia significativa <0.05. ²FMA-UE. Puntuación obtenida en la evaluación de Fugl-Meyer de Miembro superior. ³NA, No Aplicable. Los participantes sin deterioro motor no fueron evaluados con la escala clínica.

2.2. Equipos empleados

Los equipos empleados durante las sesiones experimentales se han representado en la Figura 1. En la mesa se colocó un tapete con diferentes marcas indicando cómo debe colocarse el participante, cómo colocar los elementos durante ciertos ejercicios y dónde colocar el pulsador que debe pulsarse al inicio y al final de cada actividad. Además, un ordenador portátil se coloca frente al paciente con una plataforma software que incluye un banco de ejercicios donde se muestra el movimiento que debe realizar el usuario.

La medida de los ángulos articulares del miembro superior se realizó mediante tres IMUs XSens Dot. Estos dispositivos se colocaron sobre la extremidad a evaluar en las posiciones y orientaciones requeridas por el algoritmo empleado (ver 2.3.1).

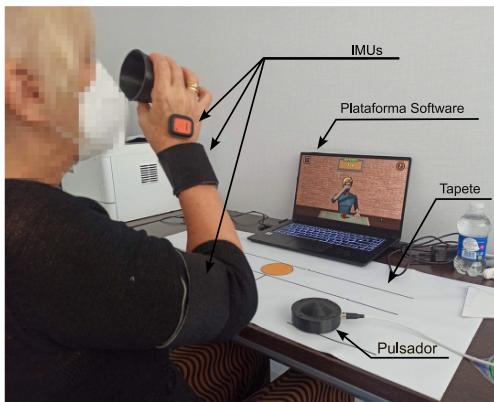


Figura 1: Equipos empleados durante las sesiones experimentales.

2.3. Sistema inteligente para evaluación de la capacidad motora del miembro superior

La arquitectura del sistema de evaluación del miembro superior se ha representado en la Figura 2. El sistema se compone de tres bloques principales: un sistema de medida de los ángulos articulares basado en IMUs, un sistema de clasificación para reconocer la actividad realizada por el usuario y un sistema de evaluación del usuario para valorar la calidad de la trayectoria realizada.

2.3.1. Medida de ángulos articulares

El sistema de medida de los ángulos articulares del miembro superior está basado en un algoritmo de reconstrucción cinemática que emplea tres IMUs (Bertomeu-Motos et al., 2018, 2023). El sistema permite medir la abducción/aducción

de hombro, la flexión/extensión de hombro, la rotación interna/externa del hombro, la flexión/extensión de codo y la pronosupinación del antebrazo. Para ello, los tres sensores se deben colocar de la siguiente manera: un primer sensor en la parte superior del brazo aproximadamente 5 cm por encima del epicóndilo lateral del húmero, un segundo sensor en el dorso de la muñeca y un tercer sensor en el dorso del carpo.

2.3.2. Reconocimiento de actividades del miembro superior

Como en el setup experimental se incluye un botón para detectar el inicio y el final de cada ensayo, las trayectorias de las articulaciones del miembro superior pueden utilizarse como entradas de un modelo de ML para reconocer la actividad realizada. Los usuarios pueden completar el movimiento especificado a su propio ritmo. Cabe destacar que la arquitectura del modelo de ML propuesto tiene capas convolucionales. Por lo tanto, como el modelo requiere un tamaño de entrada fijo, cada trayectoria q_i ha sido remuestreada con el método de Fourier (*Fourier Transform Resampling*, FTRS) a un tamaño fijo de 100 muestras. En este contexto, $q_{r,i}$ representa los datos de la trayectoria remuestreados para cada articulación, donde $q_{r,i} \in \{s_1, s_2, \dots, s_{100}\}$. Estas trayectorias conjuntas se combinan en un vector $x_A = [q_{r1}, q_{r2}, q_{r3}, q_{r4}, q_{r5}]$ con un tamaño de 100×5 , que es la entrada del modelo. La salida del modelo de clasificación es un vector $\hat{y}_A = [\hat{y}_{A1}, \hat{y}_{A2}, \dots, \hat{y}_{A12}]$, donde $\hat{y}_{A,i}$ representa el valor softmax para cada clase, que puede entenderse como la probabilidad de clasificación para cada una de las actividades posibles.

En problemas de clasificación, la actividad clasificada A se determina comúnmente seleccionando la clase con el valor softmax más alto, que puede expresarse formalmente como

$$A = \text{argmax}(\hat{y}_A) \quad (1)$$

Dado que el deterioro motor relacionado con el ictus puede dar lugar a una gran variabilidad en los patrones de movimiento de las extremidades superiores (Schwarz et al., 2022), el modelo de clasificación podría inferir incorrectamente la actividad realizada, especialmente cuando se evalúan pacientes con un deterioro motor moderado. Para filtrar las clasificaciones de movimiento incorrectas, se propone utilizar un umbral de clasificación t_C para clasificar automáticamente las trayectorias en los que $\hat{y}_{A,i} > t_C$. Por lo tanto:

$$A = \text{argmax}(\hat{y}_A), \text{ si } \max(\hat{y}_A) > t_C \quad (2)$$

Por otro lado, el resto de las trayectorias se almacenarán en una base de datos para que el terapeuta los etiquete manualmente.

2.3.3. Evaluación de las trayectorias

Una vez etiquetados los movimientos, se comparan con una base de datos de usuarios sin discapacidad para evaluar la calidad de la trayectoria realizada. En primer lugar, se calculan las distancias entre la trayectoria conjunta q_i y las trayectorias conjuntas almacenadas en la base de datos de expertos para la actividad realizada mediante el algoritmo de deformación temporal dinámica (*Dynamic Time Warping*, DTW) (Sakoe and Chiba, 1978), que es un método el cual permite medir la distancia entre dos secuencias temporales que pueden variar en velocidad. La base de datos de expertos almacena

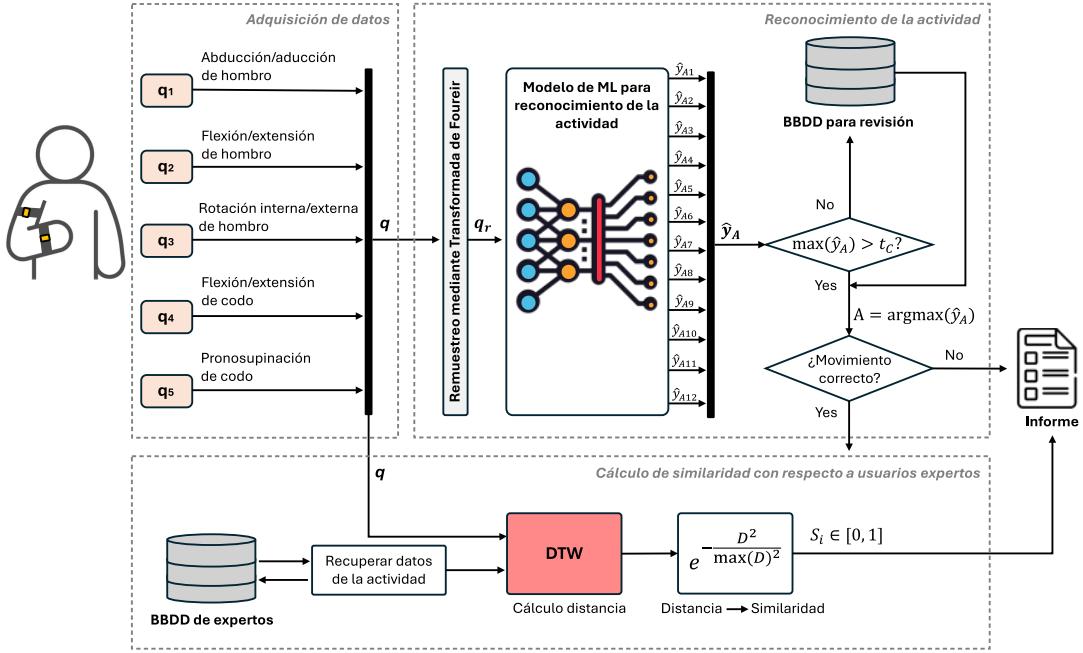


Figura 2: Procesos involucrados en el sistema propuesto para la evaluación de la función motora del miembro superior. El sistema se basa en tres IMU para medir el ángulo de las articulaciones del miembro superior, y las trayectorias de las articulaciones (q_i) se utilizan para reconocer la actividad. Además, el sistema aprovecha la distancia DTW para extraer índices de similaridad (S_i) con el fin de evaluar la calidad de la trayectoria en comparación con usuarios sin discapacidad (base de datos de expertos).

un cierto número de trayectorias para cada actividad, denotado como N_{EDB} . Por lo tanto, la distancia DTW resultante calculada para cada q_i es una matriz cuadrada D_i de tamaño $(N_{EDB} + 1) \times (N_{EDB} + 1)$, donde cada elemento de la matriz es la distancia por pares entre las trayectorias.

Además, partiendo de D_i se calcula un índice de similaridad (S_i), permitiendo convertir las medidas de distancia a un formato más intuitivo y accesible, facilitando a los terapeutas la interpretación de los datos. A partir de D_i , se calcula una matriz de similitud SM_i utilizando una función gaussiana definida como:

$$SM_i = e^{-\frac{D_i^2}{\max(D_i)^2}} \quad (3)$$

A partir de SM_i , se calcula un índice de similaridad medida S_i para cada q_i entre las trayectorias del paciente y de los expertos.

2.3.4. Preprocesamiento de datos

El dataset $\mathcal{D}_A : \{(x_A, y_A)\}_{i=1}^{n_A}$ donde t es el número de trayectorias se ha empleado para el entrenamiento de un modelo capaz de reconocer actividades de miembro superior mediante el sistema de IMUs. \mathcal{D}_A incluye trayectorias grabadas de usuarios sanos y pacientes, e incluye las trayectorias remuestreadas y una etiqueta de la actividad realizada por el usuario.

Para la evaluación de varios modelos de ML, el 30 % de los usuarios de cada grupo se ha separado de forma aleatoria para comprobar el rendimiento de los modelos con datos de usuarios que no participan en el proceso de aprendizaje (usuarios de test). Del 70 % restante de usuarios, los datos se volvieron a separar en dos nuevos datasets: el 80 % para el entrenamiento de los modelos y el 20 % como conjunto de validación.

Además, el vector de entradas x_A se escaló entre los valores mínimo y máximo de los valores articulares del conjunto de entrenamiento. De esta forma, todos los valores articulares

de las trayectorias del conjunto de entrenamiento se encuentran entre 0 y 1. Este escalado también se utilizó para evaluar el modelo con los conjuntos de datos de validación y test.

2.3.5. Modelo de ML para reconocimiento de actividades

El problema de reconocimiento de actividades se aborda como un problema de clasificación de series temporales multivariantes. Para ello, se ha propuesto un modelo compuesto por capas convolucionales unidimensionales, con un mecanismo de atención convolucional introducido por Serrà et al. (Serrà et al., 2018), y una capa de Global Average Pooling (GAP).

La primera capa convolucional unidimensional se compone de 512 filtros con un tamaño de kernel de 21; la segunda capa convolucional se compone de 256 filtros con un tamaño de kernel de 11; y la tercera capa convolucional se compone de 128 filtros con un tamaño de kernel de 5. Cada convolución va seguida de una operación de normalización *instance normalization* cuya salida se alimenta a la función de activación PReLU. A la salida de la función PReLU le sigue una operación de dropout con una tasa de 0.2 y una capa final de max pooling de 2. Tras estas capas, la mitad de los filtros se introducen en una activación softmax en función del tiempo, que actúa como mecanismo de atención para la otra mitad de los filtros. El resultado del mecanismo de atención se pasa finalmente a través de una capa GAP. Por último, una capa con doce neuronas se utiliza como la salida del modelo, donde la función de activación softmax se utilizó para nuestro problema de clasificación multinomial.

El modelo emplea la *Categorical Cross-Entropy* (CE) como función de coste y Adam como optimizador, con una tasa de aprendizaje de 0,001. Para evitar el sobreajuste, se monitoreó el error en el conjunto de validación y se aplicó parada anticipada si no mejoraba en cinco épocas, con un máximo de 250 épocas. Al detenerse el entrenamiento, se restaura-

ron los parámetros con mejor rendimiento. Además, se realizó un ajuste de hiperparámetros para optimizar el desempeño del modelo en términos de CE.

Se han entrenado y evaluado diversos modelos de clasificación State-of-the-Art (SOTA) para comparar el rendimiento del modelo propuesto con arquitecturas utilizadas para la clasificación de series temporales o arquitecturas utilizadas en trabajos relacionados: una Red Completamente Convolucional (FCN) Rosafalco et al. (2020), una Red Residual (ResNet) Wang et al. (2017), un modelo LeNet Temporal (t-LeNet) Le Guennec et al. (2016), una red convolucional temporal (Time-CNN) Zhao et al. (2017), un modelo LSTM, y un modelo ENCODER Serra et al. (2018). Además, como el estudio realizado por M. Panwar et al. se llevó a cabo con supervisores de ictus Panwar et al. (2019), también se implementó RehabNet para comparar el rendimiento de esta arquitectura con nuestro modelo.

2.4. Análisis estadístico

Se realizó un análisis estadístico utilizando el paquete de software R para evaluar las diferencias en S_i entre los tres grupos de estudio. La normalidad de las variables se comprobó mediante la prueba de Shapiro-Wilk. A continuación, se realizó un análisis de la varianza (ANOVA) para identificar diferencias significativas en S_i entre los grupos. Cuando se detectaron diferencias significativas, se realizaron comparaciones por pares utilizando la corrección de Holm-Bonferroni.

Los resultados se presentan como medias y desviaciones estándar (SD), y los valores p inferiores a 0,05 se consideran estadísticamente significativos.

3. Resultados y discusión

La Tabla 2 recoge los datos de precisión obtenida cuando los modelos entrenados se evalúan con los conjuntos de entrenamiento, validación y test. Nuestro modelo alcanza una precisión del 74.7 % con el conjunto de datos de validación y del 72.3 % con el conjunto de datos de test, superando a los otros modelos entrenados. Además, es importante tener en cuenta que el deterioro motor relacionado con el ictus puede dar lugar a una gran variabilidad en los patrones de movimiento, esperándose un aumento a medida que aumenta el grado de discapacidad Schwarz et al. (2022). Por lo tanto, las actividades reconocidas sólo se aceptan cuando el valor softmax asociado a esa actividad es superior a t_C , umbral que se ha fijado de acuerdo con la distribución de los valores softmax. Por el contrario, el movimiento realizado se trasladará a una base de datos para ser etiquetado manualmente por el terapeuta. Con el conjunto de datos de validación, el valor softmax medio para clasificaciones incorrectas es 0.490, y la mediana es 0.441. Tras ajustar $t_C = 0,5$, el modelo alcanzó una precisión del 85.7 %, descartándose del conjunto de datos de prueba el 23 % de los movimientos (Tabla 3). Un análisis posterior dividiendo el conjunto de datos de test por grupos muestra que tanto la precisión como los trayectorias clasificadas disminuyen en función del aumento de la discapacidad motora. Este comportamiento confirmaría la esperada variabilidad de los patrones en las trayectoria relacionada con el deterioro motor del miembro superior.

Tabla 2: Precisión con los conjuntos de entrenamiento, validación y test. El modelo propuesto se ha comparado con otras arquitecturas.

| Modelo | Entrenamiento | Validación | Test |
|------------------|---------------|------------|-------|
| FCN | 0.337 | 0.295 | 0.292 |
| ResNet | 0.289 | 0.226 | 0.234 |
| tLeNet | 0.117 | 0.144 | 0.124 |
| Time-CNN | 0.131 | 0.082 | 0.126 |
| LSTM | 0.722 | 0.575 | 0.529 |
| ENCODER | 0.809 | 0.514 | 0.566 |
| RehabNet | 0.620 | 0.493 | 0.409 |
| Modelo propuesto | 0.990 | 0.747 | 0.723 |

Tabla 3: Precisión y porcentaje de trayectorias clasificadas con los conjuntos de validación y test tras aplicar el umbral de clasificación t_C . También se han separado los resultados por grupos con el dataset de test.

| Dataset | Precisión | Trayectorias clasificadas |
|------------|-----------|---------------------------|
| Validación | 0.891 | 0.75 |
| Test | 0.857 | 0.77 |
| CONTROL | 0.919 | 0.86 |
| LEVES | 0.866 | 0.85 |
| MODERADOS | 0.742 | 0.54 |

Los resultados de los índices de similaridad S_i calculados se han representado en la Figura 3. El grupo CONTROL muestra S_i más altos en todas las articulaciones (q_1 a q_5), lo que indica patrones de movimiento articular más uniformes y coherentes en comparación con los grupos con funcionalidad motora reducida. En cambio, los grupos LEVE y MODERADO muestran S_i más bajos.

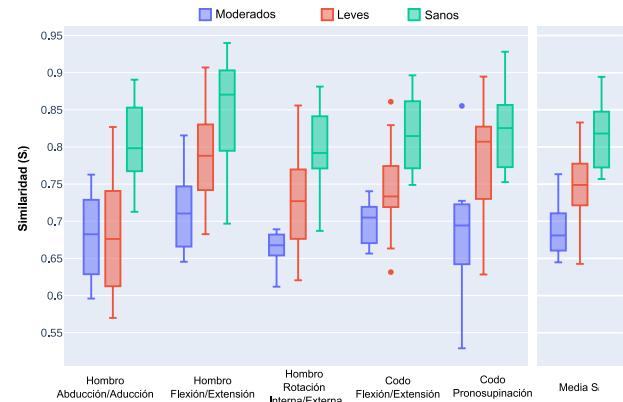


Figura 3: Distribución de S_i para cada grupo.

El estudio estadístico realizado mediante ANOVA demuestra que existen diferencias significativas entre los grupos para todos los S_i (p -valores < 0.001). Los resultados de la Tabla 4 revelan diferencias significativas entre grupos para los S_i de las trayectorias articulares y la S_i media, evidenciadas por los p -valores del test post-hoc de Holm-Bonferroni. Según los resultados, la similaridad del grupo CONTROL con respecto a la base de datos de expertos es significativamente superior a la de los pacientes LEVES para cada q_i y la S_i media en todas las articulaciones medidas, excepto para la pronosupinación (p -valor = 0,203). Estas diferencias en la similaridad de las trayectorias son más notables en la comparación por pares

del grupo MODERADO con respecto al CONTROL, donde se registran diferencias significativas para todas las q_i , así como para la similaridad media. Además, se encontraron diferencias significativas entre el grupo LEVE y el MODERADO excepto para la abducción/aducción del hombro (valor $p = 0,848$).

Tabla 4: Comparación por pares (p-valores) entre grupos para cada S_i . Los resultados han sido obtenidos con el test post-hoc the Holm-Bonferroni.

| S_i | Control-Leves | Control-Moder. | Leves-Moder. |
|-------|---------------|----------------|--------------|
| q_1 | < 0.001 | < 0.001 | 0.848 |
| q_2 | 0.064 | 0.012 | 0.016 |
| q_3 | 0.016 | < 0.001 | 0.016 |
| q_4 | 0.003 | < 0.001 | 0.012 |
| q_5 | 0.203 | < 0.001 | 0.007 |
| Media | 0.003 | < 0.001 | 0.004 |

El análisis de las S_i extraídas mediante la distancia DTW muestran que dicha S_i decrece según aumenta el grado de discapacidad motora. Por tanto, estos índices pueden emplearse como una medida fácil de comprender por el personal clínico para evaluar la calidad de la trayectoria realizada por los pacientes.

Por último, cabe mencionar que este estudio tiene varias limitaciones que deben tenerse en cuenta. En primer lugar, las actividades propuestas para la evaluación con el sistema inteligente no requieren el rango máximo de movimiento, como se suele especificar en las escalas clínicas. Por lo tanto, este dispositivo serviría como complemento a las escalas clínicas para el seguimiento del paciente en casa. En trabajos futuros se tratará de ampliar el tamaño de la muestra y se pretende realizar evaluaciones de seguimiento del paciente para detectar posibles cambios en su evolución.

4. Conclusiones

Este estudio propone un sistema de evaluación inteligente basado en IMUs y ML para analizar la función motora en terapias de telerehabilitación. Primero, verifica si el usuario ejecuta la actividad requerida mediante un modelo de clasificación. Luego, compara las trayectorias articulares de los pacientes con una base de datos de usuarios expertos en diferentes AVD. Finalmente, calcula índices de similaridad con la distancia DTW, ofreciendo a los profesionales sanitarios una medida objetiva de la alineación del movimiento del paciente con el de individuos sanos.

De acuerdo con los resultados, el modelo de reconocimiento de actividades de miembro superior alcanza una precisión del 85,7 % con el conjunto de datos de test, dejando un 23 % de las muestras para ser etiquetadas manualmente por el terapeuta cuando se aplica el umbral t_C . Además, se encontraron diferencias significativas en los índices S_i entre los grupos poblacionales. Por lo tanto, estos índices pueden ser utilizados como una medida fácil de entender por los terapeutas para evaluar la calidad de la trayectoria realizada.

Agradecimientos

Este trabajo ha sido financiado por el Ministerio de Universidades a través de la beca de Formación de Profesorado

Universitario FPU20/05137, por la Conselleria de Educación, Cultura, Universidades y Empleo de la Comunidad Valenciana a través de la ayuda CIPROM/2022/12 y por la Agencia Estatal de Investigación a través de los proyectos TED2021-130431B-I00 y PID2022-139957OB-I00.

Referencias

- Bertomeu-Motos, A., Blanco, A., Badesa, F. J., Barrios, J. A., Zollo, L., García-Aracil, N., 2018. Human arm joints reconstruction algorithm in rehabilitation therapies assisted by end-effector robotic devices. *Journal of neuroengineering and rehabilitation* 15, 1–11.
- Bertomeu-Motos, A., Ezquerro, S., Barrios, J. A., Catalán, J. M., Blanco-Ivorra, A., Martínez-Pascual, D., García-Aracil, N., 2023. Feasibility of an intelligent home-based neurorehabilitation system for upper extremity mobility assessment. *IEEE Sensors Journal* 23 (24), 31117–31124. DOI: 10.1109/JSEN.2023.3326531
- Bohannon, R. W., Smith, M. B., 1987. Interrater reliability of a modified ash-worth scale of muscle spasticity. *Physical therapy* 67 (2), 206–207.
- Fugl-Meyer, A. R., Jääskö, L., Leyman, I., Olsson, S., Steglind, S., 1975. A method for evaluation of physical performance. *Scand J Rehabil Med* 7 (1), 13–31.
- Gorelick, P. B., 2019. The global burden of stroke: persistent and disabling. *The Lancet Neurology* 18 (5), 417–418.
- Le Guennec, A., Malinowski, S., Tavenard, R., 2016. Data augmentation for time series classification using convolutional neural networks. In: ECM-L/PKDD workshop on advanced analytics and learning on temporal data.
- Maceira-Elvira, P., Popa, T., Schmid, A.-C., Hummel, F. C., 2019. Wearable technology in stroke rehabilitation: towards improved diagnosis and treatment of upper-limb motor impairment. *Journal of neuroengineering and rehabilitation* 16, 1–18.
- Moulaei, K., Sheikhtaheri, A., Nezhad, M. S., Haghdoost, A., Gheysari, M., Bahaadinbeig, K., 2022. Telerehabilitation for upper limb disabilities: a scoping review on functions, outcomes, and evaluation methods. *Archives of Public Health* 80 (1), 196.
- Panwar, M., Biswas, D., Bajaj, H., Jörges, M., Turk, R., Maharatna, K., Acharyya, A., 2019. Rehab-net: Deep learning framework for arm movement classification using wearable sensors for stroke rehabilitation. *IEEE Transactions on Biomedical Engineering* 66 (11), 3026–3037.
- Rosafalco, L., Manzoni, A., Mariani, S., Corigliano, A., 2020. Fully convolutional networks for structural health monitoring through multivariate time series classification. *Advanced Modeling and Simulation in Engineering Sciences* 7 (1), 38.
- Sakoe, H., Chiba, S., 1978. Dynamic programming algorithm optimization for spoken word recognition. *IEEE transactions on acoustics, speech, and signal processing* 26 (1), 43–49.
- Schwarz, A., Bhagubai, M. M., Nies, S. H., Held, J. P., Veltink, P. H., Buurke, J. H., Luft, A. R., 2022. Characterization of stroke-related upper limb motor impairments across various upper limb activities by use of kinematic core set measures. *Journal of neuroengineering and rehabilitation* 19, 1–18.
- See, J., Dodakian, L., Chou, C., Chan, V., McKenzie, A., Reinkensmeyer, D. J., Cramer, S. C., 2013. A standardized approach to the fugl-meyer assessment and its implications for clinical trials. *Neurorehabilitation and neural repair* 27 (8), 732–741.
- Serra, J., Pascual, S., Karatzoglou, A., 2018. Towards a universal neural network encoder for time series. In: CCIA. pp. 120–129.
- Steinmetz, J. D., Seeher, K. M., Schiess, N., Nichols, E., Cao, B., Servili, C., Cavallera, V., Cousin, E., Hagins, H., Moberg, M. E., et al., 2024. Global, regional, and national burden of disorders affecting the nervous system, 1990–2021: a systematic analysis for the global burden of disease study 2021. *The Lancet Neurology* 23 (4), 344–381.
- Velozo, C. A., Woodbury, M. L., 2011. Translating measurement findings into rehabilitation practice: an example using fugl-meyer assessment-upper extremity with patients following stroke. *Journal of Rehabilitation Research & Development* 48 (10).
- Wang, X., Zhang, J., Xie, S. Q., Shi, C., Li, J., Zhang, Z.-Q., 2024. Quantitative upper limb impairment assessment for stroke rehabilitation: a review. *IEEE Sensors Journal* 24 (6), 7432–7447.
- Wang, Z., Yan, W., Oates, T., 2017. Time series classification from scratch with deep neural networks: A strong baseline. In: 2017 International joint conference on neural networks (IJCNN). IEEE, pp. 1578–1585.
- Zhao, B., Lu, H., Chen, S., Liu, J., Wu, D., 2017. Convolutional neural networks for time series classification. *Journal of Systems Engineering and Electronics* 28 (1), 162–169.