

Jornadas de Automática

Caracterización de la marcha tras lesión medular mediante UMAP.

Mathilde Panier^a, Clara B. Sanz-Morère^{a*}, Jorge Gómez-García^a, Sara González-Expósito^a, Juan C. Moreno^{a,b}

^a Centro de Automática y Robótica, Consejo Superior de Investigaciones Científicas, Madrid 28500, España

^b Unidad de Neurorrehabilitación, Biomecánica y Función Sensoriomotora (HNP-SESCAM), Unidad Asociada de I+D+i al CSIC, Madrid, España

To cite this article: Panier, M, Sanz-Morère, C, Gómez-García, J, González-Expósito, S, Moreno, J.C. 2026. Unsupervised analysis of gait recovery after spinal cord injury. *Jornadas de Automática*, 47. <https://doi.org/10.17979/ja-cea.2026.47.13773>

Resumen

La recuperación de la marcha en pacientes con lesión medular incompleta presenta una elevada variabilidad interindividual, difícil de caracterizar mediante métricas clínicas convencionales. La integración de variables clínicas, biomecánicas y neurofisiológicas permite obtener una caracterización objetiva y multidimensional de la recuperación motora, capturando tanto el rendimiento funcional como los mecanismos subyacentes de control motor. Sin embargo, esta visión global genera espacios de alta dimensionalidad que requieren herramientas computacionales específicas para su exploración. En este trabajo se propone una reducción de dimensionalidad no supervisada mediante *Uniform Manifold Approximation and Projection* (UMAP), una técnica de visualización basada en una reducción no lineal de dimensionalidad, aplicada a datos multimodales longitudinales de cuatro pacientes con un nivel similar de independencia funcional. Los resultados muestran agrupaciones diferenciadas por sujeto en el espacio bidimensional, sin un patrón longitudinal común, lo que refleja la heterogeneidad del proceso de recuperación. Este trabajo constituye una primera aproximación exploratoria con vistas a desarrollar modelos de aprendizaje automático para la clasificación y predicción individualizada de la recuperación funcional de la marcha.

Palabras clave: Lesión medular, Marcha, Neurorrehabilitación, Datos multimodales, Reducción de dimensionalidad, Aprendizaje automático.

Unsupervised analysis of gait recovery after spinal cord injury

Abstract

Gait recovery in patients with incomplete spinal cord injury exhibits high inter-individual variability, which is difficult to characterize using conventional clinical metrics. The integration of clinical, biomechanical, and neurophysiological variables enables an objective and multidimensional characterization of motor recovery, capturing both functional performance and the underlying mechanisms of motor control. However, this global view generates high-dimensional feature spaces that require specific computational tools for exploration. This study proposes an unsupervised dimensionality reduction using Uniform Manifold Approximation and Projection (UMAP), a non-linear dimensionality reduction technique, applied to longitudinal multimodal data from four patients with similar levels of functional independence. Results show subject-specific groupings in the two-dimensional projection with no common longitudinal pattern, reflecting the heterogeneity of the recovery process. This work represents a first exploratory step towards the development of machine learning models for individualized classification and prediction of gait recovery.

Keywords: Spinal Cord Injury, Gait, Neurorehabilitation, Multimodal Data, Dimensionality Reduction, Machine Learning.

1. Introducción

La lesión medular (LM) es una alteración neurológica causada por un daño traumático o no traumático de la médula espinal que produce déficits motores, sensitivos y autonómicos por debajo del nivel de lesión (*Spinal cord injury*, 2024). Se estima que más de 15 millones de personas viven actualmente con LM en el mundo, con una incidencia global aproximada de 24 nuevos casos por millón de habitantes al año (Lu *et al.*, 2024). La pérdida de la capacidad de marcha constituye una de las principales consecuencias funcionales de esta patología y representa uno de los objetivos prioritarios de la neurorrehabilitación, debido a su impacto directo sobre la independencia funcional, la participación social y la calidad de vida (Ditunno *et al.*, 2013)(Lee y Jeoung, 2025).

En pacientes con LM incompleta, la recuperación de la marcha presenta una elevada variabilidad interindividual (van Middendorp *et al.*, 2011), de modo que pacientes con características físicas similares pueden responder de manera distinta a un mismo tratamiento. Actualmente, los mecanismos biomecánicos y neurofisiológicos que subyacen a la rehabilitación aún no están completamente establecidos (Ditunno *et al.*, 2007). En este contexto, en los últimos años ha aumentado el interés por complementar las escalas clínicas convencionales con medidas instrumentadas objetivas. Entre ellas, los expertos recomiendan integrar el análisis tridimensional de la marcha, la electromiografía de superficie, la cuantificación de la fuerza muscular y la evaluación neurofisiológica mediante potenciales evocados motores. La combinación de estas herramientas permite una caracterización más completa y precisa del estado funcional del paciente comparada con las escalas clínicas (Kesar, 2023). Además, este proceso podría permitir el desarrollo de modelos de clasificación y predicción que faciliten la personalización y adaptación de los tratamientos de rehabilitación a las necesidades de cada paciente.

Sin embargo, la integración de un número elevado de señales biomédicas objetivas provenientes de varios niveles funcionales genera espacios de características de alta dimensionalidad con cientos de variables por sesión. Antes de construir modelos de aprendizaje sobre estos datos, resulta necesario explorar su estructura subyacente para comprender cómo se organizan los pacientes y sus trayectorias de recuperación en el espacio multimodal.

En este contexto surgen las técnicas de reducción de dimensionalidad, cuyo objetivo es proyectar datos de alta dimensión en representaciones de baja dimensión preservando la estructura relevante. El Análisis de Componentes Principales (PCA) es el método lineal de referencia, pero asume relaciones lineales entre variables, lo que limita su capacidad para capturar estructuras complejas en datos biomédicos heterogéneos (Cunningham y Ghahramani, 2015). Métodos alternativos de selección de variables, como el análisis de la varianza (ANOVA), permiten identificar las características más discriminativas antes de construir modelos clasificadores, pero no proporcionan una representación visual del espacio de alta dimensión (Panier *et al.*, 2026).

Las técnicas no lineales de reducción de dimensionalidad superan estas limitaciones modelando la geometría intrínseca de los datos. Entre ellas, *t-distributed Stochastic Neighbor Embedding* (t-SNE) construye una distribución de probabilidad sobre pares de puntos en alta dimensión y busca una proyección de baja dimensión que preserve las similitudes locales, priorizando la estructura de vecindad próxima (Cai y Ma, 2021). *Uniform Manifold Approximation and Projection* (UMAP) parte de un marco teórico diferente: asume que los datos se distribuyen a lo largo de una variedad riemanniana (una superficie curva de menor dimensión que captura la geometría intrínseca de los datos), construye un grafo de vecindad ponderado para aproximar su geometría y optimiza una proyección en baja dimensión minimizando la divergencia entre ambas representaciones (McInnes, Healy y Melville, 2020). Frente a t-SNE, UMAP preserva mejor la estructura global del espacio de características, escala de forma más eficiente con el tamaño del conjunto de datos y ha demostrado utilidad en la visualización de datos biomédicos complejos y en la identificación de subgrupos clínicos (Becht *et al.*, 2019).

En el ámbito de la neurorrehabilitación, UMAP se ha empleado para explorar la organización subyacente de datos de marcha complejos, identificar agrupaciones entre perfiles funcionales distintos y visualizar trayectorias de recuperación longitudinal en espacios de alta dimensión, constituyendo así una herramienta de análisis exploratorio previa al desarrollo de modelos supervisados (Jamieson *et al.*, 2023).

El presente estudio propone un análisis no supervisado de la recuperación funcional de la marcha en pacientes con LM incompleta mediante UMAP, utilizando datos multimodales longitudinales. El objetivo específico es investigar si pacientes con un nivel funcional similar se distribuyen de forma diferenciada en la proyección bidimensional obtenida mediante UMAP, y si sus trayectorias longitudinales a lo largo del proceso de rehabilitación presentan patrones comunes o respuestas heterogéneas entre sujetos.

2. Materiales y métodos

2.1. Reclutamiento y participantes

Este estudio se enmarca dentro del proyecto NIMBLE (*Promoting neuroplastic mechanisms with modeling-based optimization of a novel robot-assisted walking rehabilitation therapy*, PID2021-123657OB-C31) y su continuación NIMBLE-NEXT (*Integrating physiological features and user experience into model-based optimization of a novel FES-robot gait therapy*, PID2024-157280OB-C31), financiados por el Ministerio de Ciencia e Innovación – Agencia Estatal de Investigación (MICIU/AEI/10.13039/501100011033) y por el Fondo Europeo de Desarrollo Regional (FEDER, UE). El protocolo recibió la aprobación del Comité Ético del Complejo Hospitalario Universitario de Toledo el 26 de abril de 2023 (Certificado nº 1008) y cumplió con los principios establecidos en la Declaración de Helsinki. Todos los sujetos participaron tras la firma del consentimiento informado.

En este estudio se reclutaron pacientes del Hospital Nacional de Paraplégico con los siguientes criterios de inclusión: presentar una LM incompleta motora (American Spinal Injury Association Impairment Scale C–D), nivel neurológico comprendido entre C5 y L1, encontrarse en fase

subaguda de la lesión, tener entre 18 y 80 años, capacidad para comprender y seguir instrucciones, y un grado de espasticidad moderado evaluado mediante la escala modificada de Ashworth ($MAS \leq 2$).

Se excluyeron aquellos pacientes con contraindicaciones para la valoración neurofisiológica, espasticidad severa, patología musculoesquelética en miembros inferiores que limitara la marcha, cirugía reciente, comorbilidades severas, embarazo, antecedentes de epilepsia o ausencia de consentimiento para participar.

2.2. Protocolo de rehabilitación y evaluación

Los participantes realizaron un programa de rehabilitación de la marcha asistida con Lokomat durante 2 meses (representando un total de 40 sesiones). Cada sesión tuvo una duración de 1 hora, incluyendo la preparación del paciente y al menos 30 minutos de entrenamiento activo. Se realizaron cuatro sesiones de evaluación: antes del inicio de la terapia (PRE), a mitad del tratamiento (MID), al finalizar (POST) y un mes después (FU). En cada evaluación se analizaron cinco niveles: capacidad funcional, fuerza máxima isométrica, excitabilidad corticoespinal, análisis tridimensional de la marcha y electromiografía de superficie.

La capacidad funcional se valoró mediante escalas clínicas estandarizadas: Walking Index for Spinal Cord Injury II (WISCI-II), Spinal Cord Independence Measure (SCIM-III), Lower Extremity Motor Score (LEMS), MAS, 10-Meter Walking Test (10MWT) y Time Up and Go (TUG), administradas por el mismo evaluador.

La fuerza muscular se cuantificó mediante una prueba de fuerza máxima isométrica (FMI), en la que el paciente realizó tres contracciones máximas contra un dinamómetro manual. Los grupos musculares evaluados fueron el glúteo medio, los cuádriceps, los isquiotibiales, el tibial anterior y el tríceps sural. El valor final de fuerza se calculó como la media de las tres mediciones, registradas en Newtons por el dinamómetro.

La excitabilidad corticoespinal se evaluó mediante potenciales evocados motores (MEPs) utilizando estimulación magnética transcraneal MagStim 200 (Magstim Company Ltd., Whitland, Reino Unido), con registros bilaterales en tibial anterior, recto femoral y abductor del hallux. Se siguió la metodología descrita en trabajos previos (Groppa *et al.*, 2012) (Cherubini *et al.*, 2024). Se calcularon como principales métricas la latencia media y la amplitud media del potencial, el umbral motor y el tiempo de conducción motora central.

El análisis tridimensional de la marcha (3DGA) se realizó mediante un sistema de captura de movimiento Vicon (Vicon Motion System LTD, Oxford, Reino Unido) con plataformas de fuerza Kistler (Kistler Ibérica S.L., Barcelona, España), ambos integrados mediante el programa Nexus versión 2.10.3 (Vicon Motion System LTD, Oxford, Reino Unido). Los participantes realizaron entre 5 y 12 pasadas en un pasillo de 10 metros llevando marcadores del modelo Plug-In-Gait modificado, permitiéndose el uso de ayudas técnicas si era necesario.

De forma simultánea, se registró la actividad muscular mediante la electromiografía de superficie (EMG) Cometa (Cometa S.r.l., Milán, Italia) en ocho músculos por extremidad inferior: recto femoral, vasto lateral, glúteo

medio, semitendinoso, bíceps femoral, tibial anterior, gastrocnemio medial y sóleo, siguiendo las recomendaciones del proyecto SENIAM (Surface EMG for Non-Invasive Assessment of Muscles) (Hermens *et al.*, 2000).

2.3. Procesamiento de datos

Para las escalas clínicas no se realizó procesamiento adicional. Se utilizaron directamente las puntuaciones obtenidas en cada prueba clínica para la construcción de la base de datos final.

La fuerza muscular se procesó a partir de las mediciones registradas por el dinamómetro manual durante las contracciones isométricas máximas.

Para los MEPs, se calcularon como métricas representativas de la excitabilidad corticoespinal la latencia media del MEP, la amplitud media del MEP, la variabilidad de la respuesta (desviación estándar de la amplitud) y el tiempo de conducción motora central.

Para el análisis tridimensional de la marcha, los datos de cinemática y cinética fueron procesados mediante modelado musculoesquelético en OpenSim (v3.3), utilizando un modelo genérico de cuerpo completo escalado a las características antropométricas de cada sujeto. Los datos continuos fueron segmentados en ciclos de marcha a partir de eventos previamente etiquetados (contacto inicial y despegue del pie), permitiendo la extracción de parámetros espaciotemporales (tiempos de paso, apoyo, cadencia y velocidad), cinemáticos (ángulos articulares y rangos de movimiento), cinéticos (momentos y potencias articulares normalizadas) y de control postural (trayectoria del centro de masas y métricas de estabilidad).

Las señales EMG registradas durante la marcha fueron filtradas (Butterworth paso banda, 20–400 Hz), rectificadas y suavizadas para obtener la envolvente muscular, segmentadas según los eventos de marcha del 3DGA y normalizadas respecto a la sesión PRE, que se empleó exclusivamente como referencia de normalización. Se extrajeron métricas representativas de la actividad muscular en el dominio temporal y frecuencial (López Gómez *et al.*, 2025).




Figura 1: Esquema del flujo de procesamiento y análisis, desde la recogida de datos multimodales hasta la proyección UMAP.




Figura 2: Perfiles individuales de las escalas clínicas a lo largo de las sesiones de evaluación. Diagramas radar de los cuatro sujetos incluidos en el análisis. Cada eje representa una escala clínica con valores normalizados y en un único valor por sesión (WISCI-II, SCIM-III, SCIM-motor, 10MWT y TUG). La SCIM-motor corresponde a la suma de los ítems de movilidad de la SCIM-III.

Antes de aplicar UMAP, se realizó un proceso de limpieza y preparación del conjunto de datos. El proceso completo desde la recogida de datos hasta el análisis UMAP se resume en la Figura 1. Dado que varios pacientes no pudieron completar todas las pruebas de evaluación en la sesión PRE debido a su estado clínico, esta sesión presentó un número elevado de valores ausentes y se empleó exclusivamente como referencia de normalización para las señales EMG, no siendo incluida en el análisis posterior.

El conjunto de datos final comprendió únicamente las sesiones MID, POST y FU. Se eliminaron variables no numéricas y columnas con varianza nula. Los valores ausentes restantes fueron imputados mediante la media de cada variable. Todas las características fueron estandarizadas mediante z-score, restando la media y dividiendo por la desviación estándar de cada variable, de modo que todas quedan expresadas en la misma escala con media cero y varianza unitaria.

2.4. Selección de sujetos y análisis exploratorio

El análisis se centró en un subconjunto de pacientes seleccionados a partir de tres criterios: una mejora de al menos 3 puntos en la SCIM-motor a lo largo de la rehabilitación, una puntuación WISCI-II suficiente para completar las pruebas de marcha y disponer de registros en los cinco niveles de evaluación. De los 10 sujetos incluidos en el estudio, 4 cumplieron estos criterios y conformaron la muestra de análisis. En primer lugar, se caracterizó la evolución clínica individual de cada sujeto mediante diagramas radar (Figura 2). Cada eje corresponde a una escala clínica: WISCI-II, SCIM-III, SCIM-motor, 10MWT y TUG. La SCIM-motor corresponde a la suma de los ítems de movilidad de la SCIM-III. En cada diagrama se superponen las sesiones PRE, MID, POST y FU, con los valores normalizados para su representación. Esta primera aproximación ofrece una visión cualitativa de la recuperación, limitada a las escalas clínicas. En segundo lugar, para extender este análisis al conjunto multimodal completo que integra además variables de fuerza, neurofisiológicas y biomecánicas, se aplicó una reducción de dimensionalidad mediante UMAP. El objetivo fue explorar la organización subyacente de los datos en un espacio de menor dimensión. Se utilizó la implementación disponible en

la librería *umap-learn* de Python (función *umap.UMAP()*) sobre la matriz de características previamente construida y estandarizada.

Se evaluaron diferentes configuraciones de los dos hiperparámetros principales. El número de vecinos más cercanos (*n_neighbors*) determina el equilibrio entre la preservación de la estructura local y global: valores bajos priorizan la estructura local y son más adecuados cuando el número de muestras es reducido, ya que valores elevados pueden introducir conexiones artificiales entre puntos distantes (McInnes, Healy y Melville, 2020). Dado el tamaño muestral de este estudio, se exploró *n_neighbors* ∈ {4, 5}. La distancia mínima entre puntos proyectados (*min_dist*) controla la compacidad de las agrupaciones en el espacio bidimensional: valores bajos producen agrupaciones más compactas y valores altos las dispersan. Se exploró *min_dist* ∈ {0.1, 0.2} para evaluar la estabilidad de las proyecciones obtenidas ante variaciones en este parámetro.

Las proyecciones bidimensionales (Figura 3) se visualizaron asignando un color a cada paciente y un marcador distinto a cada sesión (MID, POST, FU). Las sesiones de un mismo paciente se conectaron mediante flechas en orden temporal para representar la trayectoria longitudinal de cada sujeto durante la rehabilitación.

3. Resultados

Los diagramas radar (Figura 2) muestran que cada paciente presenta una forma y magnitud de cambio distinta a lo largo de las sesiones, sin un patrón común de evolución, lo que pone de manifiesto la heterogeneidad inter-sujeto en la evolución clínica. Esta heterogeneidad, interpretada cualitativamente a partir de los diagramas radar, queda confirmada de forma cuantitativa mediante las proyecciones UMAP. La exploración de hiperparámetros mostró que, en todas las configuraciones evaluadas, las observaciones de cada sujeto tienden a agruparse en regiones diferenciadas del espacio bidimensional, aunque la organización relativa entre sujetos y la compacidad de las agrupaciones varía entre configuraciones (Figura 3). Entre las cuatro configuraciones propuestas, la configuración con *n_neighbors* = 4 y *min_dist* = 0.2 es la que produce la mayor separación visual entre agrupaciones (resaltada en negrita en la Figura 3). En esta proyección, cada sujeto ocupa una región claramente diferenciada del espacio bidimensional. El sujeto 2 se sitúa en la región superior con




Figura 3: Proyecciones UMAP de la base de datos multimodal para las cuatro configuraciones de hiperparámetros evaluadas ($n_neighbors \in \{4, 5\}$, $min_dist \in \{0.1, 0.2\}$). Cada color representa un sujeto y cada marcador una sesión de evaluación (MID, POST, FU). Las flechas conectan las sesiones de un mismo sujeto en orden temporal. La proyección con $n_neighbors = 4$ y $min_dist = 0.2$, resaltada en negrita, fue seleccionada como visualización final.

una agrupación compacta y una trayectoria de pequeña magnitud con desplazamiento lateral entre sesiones. En contraste, el sujeto 3 ocupa la región inferior y presenta la trayectoria de mayor magnitud, con un desplazamiento vertical descendente pronunciado entre MID y POST. Los sujetos 7 y 8 muestran ambos una trayectoria de dirección ascendente a lo largo de las sesiones, aunque difieren en magnitud y orientación exacta. En conjunto, las trayectorias difieren entre sujetos tanto en dirección como en magnitud, sin que se observe un patrón longitudinal común. Cabe destacar que el Sujeto 3, que presenta la trayectoria de mayor magnitud en UMAP, muestra también la variación más pronunciada en las escalas clínicas entre sesiones. Los sujetos 7 y 8, cuyas trayectorias UMAP comparten dirección ascendente, presentan no obstante perfiles radar distintos.

4. Discusión

Este estudio aplica UMAP como herramienta exploratoria para analizar datos multimodales longitudinales en pacientes con LM incompleta. A diferencia de los algoritmos de agrupamiento no supervisado (*clustering*), que optimizan explícitamente criterios de separación entre grupos, UMAP es una técnica de reducción de dimensionalidad que proyecta los datos preservando su estructura geométrica intrínseca sin imponer agrupaciones. Las proyecciones obtenidas muestran, no obstante, una tendencia a la separación por sujeto en el espacio bidimensional, incluso entre pacientes con puntuaciones funcionales iniciales similares, aunque no idénticas. Este resultado sugiere que la combinación de variables clínicas, biomecánicas y neurofisiológicas recoge diferencias interindividuales que van más allá de lo capturado por las escalas clínicas convencionales de forma aislada. En este sentido, los diagramas radar (Figura 2) ilustran que sujetos como el 7 y el 8, cuyas trayectorias UMAP comparten una dirección ascendente similar, presentan sin embargo perfiles clínicos distintos en SCIM-III, WISCI-II, TUG y 10MWT, lo que es coherente con que su separación en el espacio UMAP esté parcialmente determinada por las variables biomecánicas y neurofisiológicas. Sin embargo, no

puede descartarse que parte de las diferencias observadas estén relacionadas con la variabilidad funcional entre sujetos. Que esta separación emerja sin haber sido impuesta por el algoritmo apoya la exploración de enfoques de aprendizaje automático supervisado para la clasificación de perfiles de recuperación.

El análisis longitudinal no evidenció un patrón común de evolución entre pacientes. Las trayectorias correspondientes a las sesiones MID, POST y FU presentaron direcciones y magnitudes variables entre sujetos, sin una tendencia compartida. Esta ausencia de patrón longitudinal común sugiere que la recuperación funcional tras LM incompleta no sigue una trayectoria uniforme, incluso en pacientes con perfiles funcionales iniciales similares, lo cual es coherente con la heterogeneidad clínica y fisiológica característica de esta patología (van Middendorp et al., 2011). La variabilidad observada podría reflejar estrategias de recuperación específicas de cada individuo, aunque con el tamaño muestral de este estudio no es posible descartar que contribuyan también factores como el ruido en los datos o la sensibilidad del método a las características particulares de cada sujeto. En cualquier caso, los resultados sugieren que UMAP es capaz de organizar datos multimodales longitudinales de forma diferenciada por sujeto, lo que apoya su uso como herramienta exploratoria previa al desarrollo de modelos de aprendizaje automático para la clasificación de perfiles de recuperación funcional.

Este trabajo presenta limitaciones relevantes. El tamaño muestral es reducido: 4 sujetos con 3 sesiones de evaluación cada uno, lo que resulta en solo 12 muestras para el análisis. Esta limitación condiciona directamente la elección de hiperparámetros: valores bajos de $n_neighbors$ son necesarios con tan pocas muestras y restringe la capacidad de generalización de los patrones observados. La sensibilidad de UMAP a la elección de hiperparámetros constituye otra limitación. En este estudio se exploró un rango estrecho de valores ($n_neighbors \in \{4, 5\}$, $min_dist \in \{0.1, 0.2\}$), justificado por el tamaño muestral, pero no puede descartarse que configuraciones fuera de este rango produzcan proyecciones distintas. Conviene matizar que los valores de

$n_neighbors$ y min_dist empleados no representan una configuración óptima generalizable, sino una elección condicionada por el reducido tamaño muestral. Al ser UMAP una técnica no supervisada, no optimiza ninguna variable objetivo, por lo que no cabe hablar de sobreajuste en sentido predictivo. No obstante, con solo 12 muestras existe el riesgo de que una configuración concreta produzca una separación visualmente nítida por azar, lo que refuerza el carácter exploratorio de los resultados. En cohortes de distinto tamaño o composición, el rango de hiperparámetros adecuado debería explorarse de nuevo, ya que no es esperable que los mismos valores resulten apropiados en todos los casos. Por último, la interpretación se basa en la inspección visual de las proyecciones. Métricas como la *trustworthiness* permiten evaluar en qué medida las relaciones de vecindad en el espacio original se preservan en la proyección bidimensional (McInnes et al., 2020), y su incorporación en trabajos futuros con mayor tamaño muestral permitiría complementar la inspección visual con una valoración cuantitativa de la calidad de las proyecciones. Por ello, los patrones observados deben considerarse evidencia exploratoria para la generación de hipótesis, no una caracterización definitiva de subgrupos clínicos.

Como líneas futuras, será necesario ampliar el tamaño muestral e incluir pacientes con diferentes niveles de capacidad funcional, para evaluar si la separación por sujeto observada se mantiene en cohortes más heterogéneas. La incorporación de la métrica de *trustworthiness* y técnicas de análisis de trayectorias longitudinales permitirá complementar la inspección visual con una valoración cuantitativa de la calidad de las proyecciones. El objetivo final es desarrollar modelos de aprendizaje automático que integren información multimodal y longitudinal para la clasificación de perfiles de recuperación y la predicción de la evolución funcional individualizada. La incorporación de métodos explicables será especialmente relevante para identificar qué variables del espacio multimodal contribuyen de forma más significativa a la separación entre sujetos, abordando así la limitación de interpretabilidad inherente a UMAP.

Agradecimientos

Los autores agradecen a todos los voluntarios y a Clara Sánchez del Valle, Diana Herrera Valenzuela, Laura Blanco Coloma, Lucía García González, Carolina Redondo Galán, Angela Alonso y Josep Maria Font Llagunes por sus contribuciones en el reclutamiento de participantes, la recogida de datos y/o el análisis de datos.

Referencias

Becht, E. et al. (2019) «Dimensionality reduction for visualizing single-cell data using UMAP», *Nature Biotechnology*, 37(1), pp. 38-44. <https://doi.org/10.1038/nbt.4314>.

Cai, T.T. y Ma, R. (2021) «Theoretical Foundations of t-SNE for Visualizing High-Dimensional Clustered Data». arXiv. <https://doi.org/10.48550/ARXIV.2105.07536>.

Cherubini, A. et al. (2024) «Multi-Level Characterization of the Recovery Process of a Stroke Survivor After 2 Months of Robotic Therapy with the Walkbot Robot», *2024 10th IEEE RAS/EMBS International Conference for Biomedical Robotics and Biomechatronics (BioRob)*, Heidelberg, Germany: IEEE, pp. 913-918. <https://doi.org/10.1109/BioRob60516.2024.10719925>.

Cunningham, J.P. y Ghahramani, Z. (2015) «Linear Dimensionality Reduction: Survey, Insights, and Generalizations».

Ditunno, J.F. et al. (2007) «Validity of the walking scale for spinal cord injury and other domains of function in a multicenter clinical trial», *Neurorehabilitation and Neural Repair*, 21(6), pp. 539-550. <https://doi.org/10.1177/1545968307301880>.

Ditunno, J.F. et al. (2013) «The Walking Index for Spinal Cord Injury (WISCI/WISCI II): nature, metric properties, use and misuse», *Spinal Cord*, 51(5), pp. 346-355. <https://doi.org/10.1038/sc.2013.9>.

Groppa, S. et al. (2012) «A practical guide to diagnostic transcranial magnetic stimulation: Report of an IFCN committee», *Clinical Neurophysiology*, 123(5), pp. 858-882. <https://doi.org/10.1016/j.clinph.2012.01.010>.

Hermens, H.J. et al. (2000) «Development of recommendations for SEMG sensors and sensor placement procedures», *Journal of Electromyography and Kinesiology: Official Journal of the International Society of Electrophysiological Kinesiology*, 10(5), pp. 361-374. [https://doi.org/10.1016/s1050-6411\(00\)00027-4](https://doi.org/10.1016/s1050-6411(00)00027-4).

Jamieson, A. et al. (2023) «Unsupervised Cluster Analysis of Walking Activity Data for Healthy Individuals and Individuals with Lower Limb Amputation», *Sensors*, 23(19), p. 8164. <https://doi.org/10.3390/s23198164>.

Kesar, T. (2023) «The Effects of Stroke and Stroke Gait Rehabilitation on Behavioral and Neurophysiological Outcomes:: Challenges and Opportunities for Future Research», *Delaware Journal of Public Health*, 9(3), pp. 76-81. <https://doi.org/10.32481/djph.2023.08.013>.

Lee, K.E. y Jeoung, B. (2025) «An analysis of the effectiveness of rehabilitation protocols for patients with spinal cord injury: A systematic review», *Journal of Public Health*, 33(7), pp. 1461-1470. <https://doi.org/10.1007/s10389-023-02115-9>.

López Gómez, S. et al. (2025) *Longitudinal characterization of the electromyographic evolution of gait in stroke survivors during robotic therapy*. Escola d'Enginyeria de Barcelona Est. <https://hdl.handle.net/2117/449487>.

Lu, Y. et al. (2024) «Global incidence and characteristics of spinal cord injury since 2000-2021: a systematic review and meta-analysis», *BMC medicine*, 22(1), p. 285. <https://doi.org/10.1186/s12916-024-03514-9>.

McInnes, L., Healy, J. y Melville, J. (2020) «UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction». arXiv. <https://doi.org/10.48550/arXiv.1802.03426>.

van Middendorp, J.J. et al. (2011) «A clinical prediction rule for ambulation outcomes after traumatic spinal cord injury: a longitudinal cohort study», *Lancet*, 377(9770), pp. 1004-1010. [https://doi.org/10.1016/S0140-6736\(10\)62276-3](https://doi.org/10.1016/S0140-6736(10)62276-3).

Panier, M. et al. (2026) «Classification of Walking Function After Spinal Cord Injury Using Longitudinal Multimodal Clinical, Strength, and Neurophysiological Data». *2026 IEEE RAS/EMBS International Conference on Biomedical Robotics and Biomechatronics (BioRob)*.

Spinal cord injury (2024). Disponible en: <https://www.who.int/news-room/fact-sheets/detail/spinal-cord-injury>.