

Jornadas de Automática

Detección inteligente de posibles situaciones de riesgo de usuarios de silla de ruedas en transporte

Perez, Nerea, Mancisidor, Aitiber*, Cabanes, Itziar, Vermander, Patrick

*Departamento de Ingeniería de Sistemas y Automática, Escuela de Ingeniería de Bilbao, Universidad del País Vasco (UPV/EHU),
Ingeniero Torres Quevedo Plaza, 1, 48013, Bilbao, Bizkaia, España.*

To cite this article: Perez, Nerea, Mancisidor, Aitziber, Cabanes, Itziar, Vermander, Patrick. 2025. Intelligent detection of possible risk situations of wheelchair users in transport. *Jornadas de Automática*, 46. <https://doi.org/10.17979/ja-cea.2025.46.12084>

Resumen

El uso del transporte puede generar situaciones de riesgo para usuarios de silla de ruedas que influyan negativamente en su estado funcional, por ello es esencial identificar las condiciones a las que están expuestos durante sus desplazamientos. Este estudio presenta un identificador, basado en IA, de posibles situaciones de riesgo para usuarios de sillas de ruedas en dos etapas. Primero, se clasifica si el usuario se encuentra en un transporte sobre raíles, ruedas o detenido. Después, se identifica si el vehículo está en movimiento, girando o frenando. Se han evaluado dos técnicas inteligentes, KNN y ANN. Ambas alcanzan un porcentaje de acierto del 98,7 % en la primera etapa. En la segunda, KNN muestra mejores resultados, con precisiones superiores al 92 %, mientras que ANN presenta valores por encima del 81 %. El sistema permite contextualizar los datos posturales recogidos en la actividad diaria de estas personas, lo que facilita su interpretación clínica y contribuye a tomar decisiones para mejorar el tratamiento.

Palabras clave: Tecnología asistencial e ingeniería de rehabilitación, Fusión de información y sensores, Técnicas de inteligencia artificial, Diseño de experimentos, Metodologías de diseño

Intelligent detection of possible risk situations of wheelchair users in transport

Abstract

The use of transportation can generate risk situations for wheelchair users that may negatively impact their functional status. Therefore, it is essential to identify the conditions they are exposed to during travel. This study presents an AI-based identifier of potential risk situations for wheelchair users, structured in two stages. First, it classifies whether the user is in rail transport, wheeled transport, or stationary. Then, it detects whether the vehicle is moving, turning, or braking. Two intelligent techniques, KNN and ANN, have been evaluated. Both achieve an accuracy rate of 98.7 % in the first stage. In the second stage, KNN shows better results, with precision rates above 92 %, while ANN presents values exceeding 81 %. The system enables the contextualization of postural data collected during the users' daily activities, facilitating clinical interpretation and supporting treatment decisions.

Keywords: Assistive technology and rehabilitation engineering, Information and sensor fusion, Artificial intelligence techniques, Experiment design, Design methodologies

1. INTRODUCCIÓN

Los usuarios de silla de ruedas se enfrentan a diversos retos cuando utilizan transporte público o privado para desplazarse. Factores del entorno ajenos a su control, como los baches en la calzada, las curvas cerradas o los frenazos repentinos, generan movimientos bruscos del vehículo que pueden llegar a alterar su postura. Estas situaciones no solo generan incomodidad, sino que pueden desencadenar alteraciones posturales que aumentan el riesgo de lesiones, fatiga muscular o problemas en la columna vertebral (2). Las vibraciones de cuerpo entero (VCE), especialmente frecuentes en trayectos largos o sobre superficies irregulares, también representan un riesgo para la salud física de los usuarios de silla de ruedas (3). En este sentido, es importante señalar que ciertos movimientos o posturas, aunque no representen un riesgo inmediato, pueden convertirse en problemáticos si se repiten con frecuencia o se mantienen durante periodos prolongados.

A pesar de que estas situaciones de posible riesgo son habituales en el día a día, apenas existen estudios que analicen cómo estos factores del entorno afectan a los usuarios de sillas de ruedas. La mayoría de investigaciones existentes sobre transporte y salud se centran en profesionales del sector o pasajeros habituales, como conductores de camión (13), de autobús (1) o viajeros de tren (14). En estos casos, se ha observado una relación entre el movimiento del vehículo, la exposición a VCE y diversos problemas físicos. Sin embargo, cuando se trata de personas que usan sillas de ruedas, la investigación se centra en aspectos como la accesibilidad (7) o la conducción autónoma (12), dejando en un segundo plano el tipo de transporte en el que se mueven y sus consecuencias en la salud de los usuarios.

En este contexto, surge la necesidad de contar con herramientas que permitan identificar no solo el tipo de transporte utilizado, sino también el tipo de movimiento que experimenta durante el trayecto. Esta información resulta especialmente útil para profesionales sanitarios, ya que permite detectar posibles situaciones de riesgo, entender mejor el contexto de cada persona y ajustar las intervenciones terapéuticas a sus condiciones reales.

En este trabajo se presentan dos modelos de identificación de posibles situaciones de riesgos para usuarios de silla de ruedas en el transporte: uno basado en el algoritmo K-Nearest Neighbors (KNN) y otro en redes neuronales artificiales (ANN). Ambos permiten detectar si el usuario se encuentra en transporte sobre ruedas (como en autobuses o coches), en transporte sobre raíles (como trenes o tranvías), o si está estacionado. Además, son capaces de distinguir el tipo de desplazamiento realizado en cada momento, clasificando entre trayectos rectos, giros o frenazos. Esta información contextual, fácilmente interpretable, puede ser clave para prevenir situaciones de riesgo y adaptar las intervenciones clínicas a la realidad cotidiana del usuario.

El resto del artículo se organiza del siguiente modo: en la Sección II se detalla el sistema de monitorización empleado y el procedimiento seguido para la generación de la base de datos. La Sección III presenta los modelos de identificación de posibles situaciones de riesgo desarrollados y los resultados obtenidos. Por último, en la Sección IV se exponen las conclusiones principales del estudio.

2. GENERACIÓN DE LA BASE DE DATOS

El propósito de este trabajo es identificar posibles situaciones de riesgo para usuarios de silla de ruedas en el transporte. Para ello, es necesario identificar el medio de transporte en el que se desplazan, de modo que esta información complemente tanto el análisis postural como la evaluación del estado funcional del usuario. Para entrenar un clasificador que permita llevar a cabo esta tarea, ha sido necesario crear una base de datos que recoja trayectos reales en distintos medios de transporte. A continuación se detalla el sistema de monitorización utilizado y la definición de los ensayos realizados

2.1. Sistema de monitorización

Para la generación de la base de datos se ha usado un sistema de monitorización capaz de registrar tanto el movimiento de la silla de ruedas como la postura del usuario durante los desplazamientos (11). Este se compone de dos módulos diferenciados: dispositivo para la monitorización postural (Figura 1 en verde) y el del movimiento de la silla (Figura 1 en naranja).



Figura 1: Sistema de monitorización compuesto por dos módulos: dispositivo de monitorización postural (en verde) y el del movimiento de la silla (en naranja).

El primer módulo, es el sistema de monitorización postural i-KuXin (9). Está formado por 16 sensores FSR (Force-Sensing Resistor) distribuidos estratégicamente sobre un cojín portable como se puede ver en la Figura 1 en amarillo. Mide la fuerza ejercida tanto en el asiento como en el respaldo, lo que permite conocer la postura corporal del usuario en cada momento.

El segundo módulo se encarga de monitorizar el movimiento de la silla de ruedas (10). Para ello, integra una Unidad de Medición Inercial (IMU), que mide aceleraciones lineales, velocidades angulares y orientación en los tres ejes. Además, cuenta con un encoder instalado en cada rueda para registrar la distancia recorrida por la silla. En total, se monitorizan 11 variables de movimiento para analizar el uso de la silla de ruedas.

La adquisición de datos se realiza en tiempo real mediante placas Arduino, con una frecuencia de muestreo de 10 Hz y transmisión inalámbrica via Bluetooth. Este sistema de monitorización ha sido integrado en la silla de ruedas eléctrica Sunrise Medical QUICKIE Q200 R que se puede ver en la Figura 1.

2.2. Definición de los ensayos

Según los usuarios y el personal sanitario de la Federación Coordinadora de Personas con Discapacidad Física y/u Orgánica de Bizkaia (FEKOOR), el impacto del trayecto recorrido varía significativamente en función del medio utilizado. Por ello, con el objetivo de capturar con precisión las particularidades de cada tipo de transporte e identificar situaciones de riesgo como aceleraciones y giros bruscos, se han llevado a cabo ensayos en diferentes medios de transporte. En concreto, se han realizado desplazamientos tanto en sistemas sobre raíles (metro y el tranvía) como en vehículos con ruedas (furgoneta adaptada).

Durante la ejecución de cada ensayo, se ha llevado un registro minucioso del recorrido y del contexto en el que se encontraba la silla de ruedas, lo cual ha facilitado el proceso de etiquetado. Dado que las señales registradas dependen más del tipo de transporte que del individuo que ocupa la silla, se ha optado por realizar los ensayos con solo dos participantes. Aun así, se ha logrado una base de datos amplia, con más de 27000 muestras recogidas en varios viajes distribuidas de la siguiente forma: 10721 en metro, 12160 en tranvía y 5436 en furgoneta.

Una vez recopilados los datos, se ha procedido a su preprocesamiento. En primer lugar, se ha aplicado un filtro interno del propio sensor inercial (IMU) con el fin de reducir el ruido y mejorar la calidad de la señal. Posteriormente, todos los datos se han normalizado mediante un escalado min-max, ajustando cada variable a un rango común para facilitar el análisis. Para capturar la dinámica del movimiento, se han utilizado ventanas deslizantes, extrayendo un conjunto de nueve características estadísticas por cada una de las variables registradas. Entre estas métricas se incluyen la media, desviación estándar, varianza, mediana, percentiles 25 y 75, valor mínimo, máximo y el rango. Este enfoque permite convertir señales continuas en descriptores numéricos representativos, fundamentales para el posterior entrenamiento del identificador de posibles situaciones de riesgo en el transporte.

3. IDENTIFICACIÓN INTELIGENTE DE POSIBLES SITUACIONES DE RIESGO EN EL TRANSPORTE

Una vez generada la base de datos, el siguiente paso ha sido diseñar el clasificador inteligente de transporte que permite identificar posibles situaciones de riesgo para usuarios de silla de ruedas. Para ello, se ha planteado un enfoque de clasificación dividido en dos fases (Figura 2). En la primera (C1), el sistema distingue entre: si el usuario se desplaza en un vehículo sobre raíles, en uno con ruedas o si permanece detenido. Una vez identificado el tipo de transporte, la segunda fase (C2) se centra en analizar el estado del movimiento, clasificando si el transporte está en marcha -sin ejecutar posibles acciones de riesgo-, si está cogiendo una curva o si se está produciendo un frenazo. Esta estructura permite afinar el reconocimiento del entorno, identificar posibles situaciones de riesgo como giros o frenazos bruscos y proporciona información clave para el análisis postural y del estado funcional posterior.

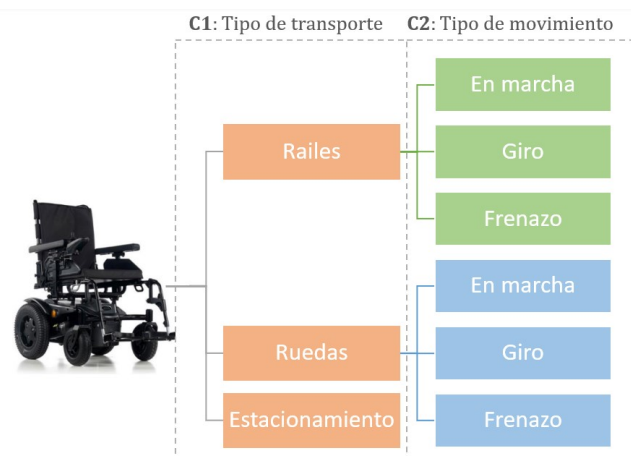


Figura 2: Esquema de la clasificación dividido en dos etapas.

Utilizando este enfoque dividido en dos etapas, se han empleado dos técnicas de aprendizaje automático ampliamente reconocidas por su efectividad en tareas de clasificación: redes neuronales artificiales (ANN) y K-Nearest Neighbors (KNN). Las ANN son modelos inspirados en el cerebro humano, capaces de aprender patrones complejos a partir de grandes volúmenes de datos (6; 8). Por otro lado, KNN es un algoritmo basado en la similitud, que clasifica una muestra según las clases de sus vecinos más cercanos en el espacio de características (4; 5). Ambas técnicas se han aplicado tanto en la primera fase de clasificación, que se encarga de identificar el tipo de transporte (sobre raíles, con ruedas o estacionado), como en la segunda fase, que clasifica el estado del transporte (en marcha, girando o frenando). Esta doble aplicación permite comparar el rendimiento de cada técnica en ambos niveles del proceso, garantizando una clasificación precisa y eficiente en todas las etapas.

En la primera etapa, utilizando las características extraídas, se lleva a cabo una clasificación preliminar del tipo de transporte (C1). Para ello, los algoritmos KNN y ANN se han entrenado con el 70 % de la base de datos. Los hiperparámetros se han ajustado previamente, estableciendo un vecino para KNN y una capa oculta de 11 neuronas para ANN. La validación se ha llevado a cabo utilizando el 30 % restante de la base de datos, obteniéndose resultados muy prometedores (Figura 3). En transporte sobre raíles se ha obtenido un porcentaje de acierto del 97,6 % con KNN y del 97,2 % con ANN; en vehículo de ruedas, un 99,8 % y un 99,6 % respectivamente; y en estado de estacionamiento, un 99,4 % y un 99,5 %.

Los resultados obtenidos con ambas técnicas de clasificación son muy elevados, superando el 97 % de precisión en todos los tipos de transporte analizados. Aunque KNN muestra un rendimiento ligeramente superior al de ANN en cada categoría, la diferencia es mínima, con una precisión media de 98,93 % para KNN y 98,77 % para ANN, lo que demuestra la solidez de ambos enfoques para esta tarea. Esta primera clasificación resulta fundamental para determinar si el usuario de silla de ruedas se encuentra en movimiento o estacionado y, en caso de movimiento, identificar el tipo de transporte utilizado.

Tabla 1: Resultados comparativos de porcentaje de acierto entre las técnicas KNN y ANN en la segunda fase de clasificación (C2).

Técnica	Categoría	C2			Media
		En marcha	Giros	Frenada	
KNN	Raíles	97.3 %	97.4 %	98.7 %	97.8 %
	Ruedas	92.9 %	94.6 %	94.7 %	94.1 %
ANN	Raíles	81.8 %	92.9 %	95.6 %	90.1 %
	Ruedas	81.2 %	84.2 %	86.8 %	84.1 %




Figura 3: Matriz de confusión para la clasificación C1 con KNN y ANN.

Estos resultados permiten avanzar a la siguiente etapa de la metodología (C2 en la Figura 2), centrada en identificar con mayor precisión las posibles situaciones riesgo específicas que ocurren dentro de cada tipo de transporte. En los casos en los que se determina que el usuario de la silla de ruedas se encuentra en un medio de transporte sobre raíles o con ruedas, se implementan modelos adicionales de clasificación utilizando KNN y ANN, siguiendo el mismo esquema de entrenamiento aplicado en la etapa anterior. Estos modelos especializados permiten distinguir entre situaciones como desplazamiento en marcha, realización de giros y frenadas.

Para el transporte sobre raíles, KNN obtiene un porcentaje de acierto del 97,3 % en marcha, 97,4 % en giros y 98,7 % en frenadas. En el mismo contexto, ANN alcanza un 81,8 % en marcha, 92,9 % en giros y 95,6 % en frenadas. En el caso del transporte con ruedas, KNN registra una precisión del 92,9 % en marcha, 94,6 % en giros y 94,7 % en frenadas, mientras que ANN logra un 81,2 % en marcha, 84,2 % en giros y 86,8 % en frenadas. Los resultados obtenidos se agrupan en la Tabla 1, que muestra la precisión alcanzada por ambos algoritmos en cada uno de los escenarios contemplados.

A partir de estos resultados, se observa que KNN mantiene un rendimiento más elevado y constante en ambos tipos de transporte, con medias de precisión del 97,8 % para raíles y del 94,1 % para ruedas. En comparación, ANN presenta una media del 90,1 % en raíles y del 84,1 % en ruedas, lo que refleja un rendimiento más limitado. Las diferencias entre ambos clasificadores son especialmente notables cuando el transporte está en marcha sin ejecutar situaciones de riesgo, donde ANN alcanza apenas un 81,8 % en raíles y un 81,2 % en ruedas, frente a los valores superiores al 92 % de KNN. Esta brecha sugiere que el modelo de red neuronal tiene mayores dificultades para generalizar correctamente el patrón asociado a este movimiento.

Además, se aprecia una diferencia consistente entre los tipos de transporte: los resultados obtenidos en escenarios sobre raíles son superiores en todos los casos respecto a los obtenidos en transporte con ruedas. Esta diferencia puede explicarse por la naturaleza del entorno: los sistemas ferroviarios siguen trayectorias fijas y presentan movimientos más uniformes, lo que facilita su detección y clasificación. Por el contrario, los desplazamientos sobre ruedas suelen producirse en entornos abiertos y menos estructurados, donde intervienen más factores impredecibles. Aun así, el modelo de clasificación global logra una precisión superior al 92 % en todas las categorías mediante el uso de KNN, lo que resulta especialmente valioso para interpretar con fiabilidad los datos de monitorización del movimiento de usuarios de sillas de ruedas y detectar posibles situaciones de riesgo.

4. CONCLUSIÓN

En este trabajo se ha desarrollado un sistema inteligente capaz de clasificar tanto el tipo de transporte como el estado de movimiento de éste, con la intención de identificar posibles situaciones de riesgo para usuarios de silla de ruedas. Para ello, se han empleado los datos recogidos por el sistema de monitorización desarrollado que mide tanto las variables de movimiento de la silla como la posición corporal del usuario. La clasificación se ha planteado en dos etapas: una primera para distinguir el tipo de transporte y una segunda para identificar su estado dinámico (en marcha, giro o frenada).

En la primera etapa, con las dos técnicas utilizadas, KNN y ANN, se ha alcanzado un rendimiento equivalente con un porcentaje de acierto medio del 98,9 % y 98,8 % respectivamente, lo que confirma su eficacia para diferenciar entre transporte sobre raíles y con ruedas. En la segunda etapa, se ha evaluado el comportamiento de los modelos en los distintos estados de movimiento dentro de cada tipo de transporte. El sistema ha

mostrado un alto rendimiento general, especialmente con el clasificador KNN, que alcanza precisiones medias superiores al 94 % en todos los contextos, destacando por su estabilidad y fiabilidad. El modelo ANN también ofrece resultados aceptables, con una precisión media del 90,1 % en transporte sobre raíles y del 84,1 % en transporte con ruedas, aunque con mayor variabilidad, especialmente en trayectos en marcha.

Más allá del rendimiento numérico, el sistema aporta un valor añadido al permitir identificar posibles situaciones de riesgo y contextualizar los movimientos posturales, lo que supone una mejora significativa en su interpretación clínica. Al combinar los datos posturales con el contexto de movimiento, es posible comprender mejor cómo influyen los distintos tipos de transporte en la postura mantenida durante los trayectos. Esto permite a los profesionales de la salud conocer mejor el estado funcional de los pacientes y tomar decisiones más ajustadas a las necesidades reales, adaptando los tratamientos y aplicando medidas preventivas específicas. Entre ellas, puede incluirse el uso de cojines especiales o cinturones y cintas de sujeción, ajustes en la rutina de movilidad o recomendaciones personalizadas para reducir el riesgo de lesiones.

Conviene aclarar que los tipos de transporte y movimientos clasificados por el sistema no implican por sí mismos una situación de riesgo absoluto, pero sí podrían tener un impacto negativo sobre la postura si se repiten de forma prolongada o frecuente. Por tanto, como trabajo futuro, se plantea incorporar un módulo de detección de anomalías contextuales posturales que permita identificar situaciones posturales atípicas durante el trayecto. Así, el sistema proporcionará información clave para adaptar los tratamientos y aplicar estrategias preventivas que minimicen el impacto del transporte sobre el estado físico del usuario.

Agradecimientos

Este trabajo ha sido financiado por: por el Gobierno Vasco, proyecto IT1726-22, y por el FEDER/Ministerio de Ciencia e Innovación - Agencia Estatal de Investiga-

ción/Proyecto PID2020-112667RB-I00 financiado por MCI-N/AEI/10.13039/501100011033.

Los autores expresan su agradecimiento a la Federación Coordinadora de Personas con Discapacidad Física y/u Orgánica de Bizkaia (FEKOOR) por su ayuda.

Referencias

- [1] Chen, Y., Wang, L., Wang, Z., Jia, N. & Chen, Q. Whole-body vibration exposure characterization in bus drivers of Haikou City: A comparison between two health risk assessment methods. *Journal of Environmental and Occupational Medicine*. **40**, 1264-1269 (2023)
- [2] Crawford, A., Armstrong, K., Loparo, K., Audu, M., & Triolo, R. Detecting destabilizing wheelchair conditions for maintaining seated posture *isabil Rehabil Assist Technology*. **13**, 178-185 (2018)
- [3] Garcia-Mendez Y., Pearlman J., Boninger M. & Cooper R. Health risks of vibration exposure to wheelchair users in the community. *The Journal of Spinal Cord Medicine*. **36**(4), 365-75 (2013.3)
- [4] Halder, R.K., Uddin, M.N., Uddin, M.A., & others. Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications. *Journal of Big Data*. **11**, 113 (2024).
- [5] Ma, C., Li, W., Cao, J., Du, J., Li, Q., Gravina, R. Adaptive sliding window based activity recognition for assisted livings. *Information Fusion*. **53**, 55-65 (2020).
- [6] Molina Menéndez, E. & Parraga-Alava, J. Artificial Neural Networks for Classification Tasks: A Systematic Literature Review. *Enfoque UTE*. **15**, 1-10 (2024).
- [7] K. Lepoglavec, O. Papeš, V. Lovrić, A. Raspudić, H. Nevečerel. Accessibility of Urban Forests and Parks for People with Disabilities in Wheelchairs, Considering the Surface and Longitudinal Slope of the Trails *Multidisciplinary Digital Publishing Institute*. **15** (2023)
- [8] Luna-Perejón, F., Montes-Sánchez, J.M., Durán-López, L., Vázquez-Baeza, A., Beasley-Bohórquez, I., Sevillano-Ramos, J.L. IoT device for sitting posture classification using artificial neural networks. *Electronics*. **10**, 1825 (2021).
- [9] Perez, N., Mancisidor, A., Cabanes, I., Vermander, P. Sitting Posture Monitoring Device for People with Low Degree of Autonomy. *Converging Clinical and Engineering Research on Neurorehabilitation IV. ICNR 2020*. (2022)
- [10] Perez, N., Mancisidor, A., Cabanes, I., Vermander, P., Portillo, E., Zubizarreta, A. Sistema de monitorización de entornos para usuarios de sillas de ruedas. *Jornadas de Automática 2024* **45** (24)
- [11] Perez, N., Mancisidor, A., Cabanes, I., Vermander, P., Gonzalez, J. Continuous postural and movement monitoring system for wheelchair users assessment. *Measurement* (2024)
- [12] M. Shyam, K. Abinash, A. Jeevan Mathew, P. R. Akash Ram, S. Kaushik, M. Kishore. A Contemporary Voice Assisted LIDAR Based Self Piloting Intelligent Wheelchair for Both Elderly And Disabled. *2023 IEEE International Conference on Research Methodologies in Knowledge Management, Artificial Intelligence and Telecommunication Engineering*. (2023)
- [13] Zhang, P., Chen, W., Wang, H., Li, Z., Li, X., Liu, B., Adam, S., Jalil, N., Razali, K., Kumar, R., Sharma, R., Kumar, V. & Khan, A. Predictors of Whole-Body Vibration Exposure among Indian Bus and Truck Drivers. *Journal Of Physics: Conference Series*. **1854**, 012033 (2021.4)
- [14] Zhou, J., Wu, Z., Fan, C., Yu, T., Yi, S., Li, Y. & Peng, Y. Evaluation and prediction method of railway passenger long-term vibration comfort under complex operating conditions. *Ergonomics*. (2023)