

Metodología de detección de anomalías en personas con esclerosis múltiple

Otamendi, J.^{a,*}, Zubizarreta, A.^a, Mancisidor, A.^a

^aDepartamento de Ingeniería de Sistemas y Automática, Escuela de Ingeniería de Bilbao, Universidad del País Vasco (UPV/EHU), 48013 Bilbao, España.

To cite this article: Otamendi, J., Zubizarreta, A., Mancisidor, A., 2023. Anomaly detection methodology for people with multiple sclerosis.

XLIV Jornadas de Automática, 77-82. <https://doi.org/10.17979/spudc.9788497498609.077>

Resumen

Las terapias personalizadas han demostrado ser capaces de ralentizar la evolución de la esclerosis múltiple, mejorando así la calidad de vida de aquellas personas que la padecen. Sin embargo, en su diseño es fundamental conocer el estado funcional de cada paciente y detectar cuanto antes los cambios que ocurran en él. Dados los inconvenientes de las técnicas tradicionales de evaluación, estudios recientes han propuesto monitorizar la marcha de los pacientes, para así poder extraer indicadores relevantes y ayudar a los especialistas en dicha labor. En este estudio, se propone una metodología basada en técnicas de aprendizaje automático, cuyo objetivo es detectar los cambios en el estado funcional de las personas con esclerosis múltiple, partiendo de los datos que proporciona una contera sensorizada. Teniendo en cuenta la variabilidad que existe entre pacientes, el diseño propuesto se centra en un enfoque individualizado, que caracteriza el estado de cada individuo utilizando sus propios datos. La metodología propuesta ha sido validada en tres personas con esclerosis múltiple, obteniendo un porcentaje de aciertos medio del 88.9 %.

Palabras clave: Tecnología asistencial e ingeniería de rehabilitación, monitorización, modelado e identificación, validación clínica, apoyo a la toma de decisiones y control.

Anomaly detection methodology for people with multiple sclerosis

Abstract

Personalized therapies have proven to be effective in slowing the progression of multiple sclerosis, thereby improving the quality of life of those people suffering from it. However, the design of such therapies requires knowledge of the patient's functional state and early detection of changes that may occur. Given the drawbacks of traditional assessment techniques, recent studies have proposed monitoring patients' gait in order to extract relevant indicators and assist specialists in this task. Given this situation, this study proposes a machine learning-based methodology, which aims to detect changes in the functional state of people with multiple sclerosis based on the data provided by a sensorized tip. Taking into account the variability that exists among patients, the proposed design focuses on an individualized approach, which characterizes the state of each individual using only his/her own data. The proposed methodology has been validated in three people with multiple sclerosis, obtaining an average accuracy of 88.9 %.

Keywords: Assistive technology and rehabilitation engineering, monitoring, modeling and identification, clinical validation, decision support and control.

1. Introducción

La esclerosis múltiple (EM) es el trastorno neurológico discapacitante no traumático más común en adultos jóvenes. Se trata de una enfermedad neurodegenerativa y crónica, cuya incidencia está aumentando en todo el mundo, junto con el impacto

socioeconómico que genera (Dobson and Giovannoni, 2019).

Aunque los síntomas de la enfermedad varían en función del área afectada, la esclerosis múltiple se asocia a menudo con una disminución de la capacidad para caminar y de mantener el equilibrio. De hecho, más de un 80 % de los pacientes requiere de un dispositivo de ayuda técnica (muleta, bastón, andador)

*Autor para correspondencia: janire.otamendi@ehu.es
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

tras 15 años desde el primer brote de la enfermedad (Souza et al., 2010).

Actualmente, no existe cura para la EM, sin embargo, estudios han demostrado que las terapias personalizadas pueden mejorar notablemente la calidad de vida de los pacientes, e incluso ralentizar la evolución de la enfermedad (Rotstein and Montalban, 2019). Para diseñar dichas terapias es necesario conocer el estado funcional de los pacientes y detectar cuanto antes los cambios que puedan ocurrir en él.

Tradicionalmente, son los especialistas los encargados de realizar la evaluación clínica utilizando para ello escalas clínicas normalizadas. Sin embargo, estas escalas pueden tener un componente subjetivo, y la obtención de sus valores requiere de la ejecución de pruebas complejas, lo que hace que la periodicidad entre las evaluaciones sea, en general, elevada (Flache-necker, 2015).

Ante esta situación, varios estudios han propuesto monitorizar la marcha de los pacientes y extraer indicadores que puedan ser relevantes para evaluar su estado funcional. Entre las diversas tecnologías que se proponen para este fin, son los dispositivos vestibles basados en sensores inerciales los que más se emplean actualmente (Müller et al., 2021; Berg-Hansen et al., 2022). Sin embargo, estos dispositivos presentan inconvenientes a la hora de utilizarlos con pacientes, ya que los métodos que se emplean para fijarlos al cuerpo pueden generar molestias (Alexander et al., 2021).

Con el objetivo de minimizar la invasividad, trabajos recientes han propuesto sensorizar dispositivos de ayuda técnica como bastones, muletas o andadores (Chamorro-Moriana et al., 2016; Fernandez et al., 2020). Estos dispositivos, al ser comúnmente utilizados por personas con problemas de movilidad, no generan rechazo y han demostrado ser una alternativa eficaz para capturar datos.

En cuanto a las aplicaciones de la monitorización de la marcha, en el ámbito de la EM, la mayoría de los trabajos existentes se centran en analizar la relación entre variables capturadas y el estado del paciente desde un enfoque estadístico (Sun et al., 2018; Berg-Hansen et al., 2022). También hay estudios que, empleando técnicas de aprendizaje automático, tratan de clasificar los patrones de diferentes enfermedades, o distinguir a estas personas de aquellas que no padecen ninguna enfermedad (Greene et al., 2015; Vajiha Begum and Rani, 2020). Estos estudios pueden proporcionar información objetiva al terapeuta, e incluso ayudar en el diagnóstico. Sin embargo, una vez caracterizado el estado funcional del paciente, la eficacia de las terapias se basa en la capacidad de adaptarlas según la evolución específica de cada individuo, área que no abarcan los trabajos anteriormente citados.

En este contexto, en este artículo se propone una metodología basada en aprendizaje automático para detectar cambios significativos en la marcha de pacientes con esclerosis múltiple que requieren un dispositivo de ayuda técnica en su día a día. El enfoque presentado, diferente a los propuestos en la literatura, se centra en la individualización de los detectores desarrollados, para ser utilizados como apoyo en el proceso de toma de decisiones del terapeuta.

El resto del artículo se estructura de la siguiente manera: en la Sección 2 se presenta el prototipo de la contera sensorizada empleada como sistema de monitorización; la Sección 3 descri-

be la metodología para el desarrollo de detectores de anomalías de la marcha; en la Sección 4 se muestra la validación de la metodología en tres personas con esclerosis múltiple; y finalmente, en la Sección 5 se resumen las ideas principales del estudio.

2. Contera sensorizada

En este estudio se utiliza la contera sensorizada presentada en (Brull et al., 2020) como elemento de monitorización de la marcha. Este dispositivo, a diferencia de las muletas o bastones propuestos en (Chamorro-Moriana et al., 2016; Fernandez et al., 2020), puede ser acoplado al dispositivo de ayuda técnica personal de cada paciente (Figura 1), lo que minimiza la invasividad.

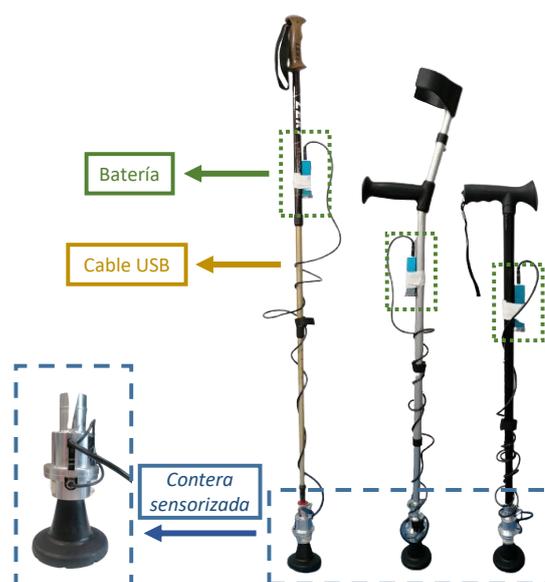


Figura 1: Contera sensorizada acoplada a distintos tipos de dispositivos de ayuda técnica.

La contera sensorizada está compuesta por un dispositivo de adquisición de datos y tres sensores: un sensor de fuerza, un barómetro y una Unidad de Medición Inercial (IMU); todos ellos integrados en una estructura de aluminio y alimentados por una batería externa.

El sensor de fuerza mide la fuerza axial ejercida por el paciente. El barómetro mide la presión atmosférica, mediante el cual se estima la altura relativa del dispositivo. Finalmente, la Unidad de Medición Inercial proporciona información sobre la aceleración lineal, la velocidad angular y el campo magnético en los ejes x , y , z locales de la contera. Este último sensor, además de capturar las señales mencionadas, también integra un algoritmo que permite estimar los ángulos de Euler en un sistema de referencia global, que se utilizan posteriormente para calcular los ángulos entre el cuerpo del paciente y su dispositivo de ayuda técnica en los planos anteroposterior y lateromedial (Brull et al., 2020).

3. Metodología de detección de anomalías

En esta sección, se detalla la metodología desarrollada para diseñar los clasificadores que se encargarán de detectar cambios

en el patrón de la marcha, y por tanto, en el estado funcional de los pacientes con esclerosis múltiple.

El sistema partirá de los datos proporcionados por la contera sensorizada descrita en la sección 2, y servirá como apoyo en el proceso de toma de decisiones del terapeuta que esté llevando el caso del paciente monitorizado.

Las siguientes subsecciones describen el procedimiento propuesto en este estudio, que se divide en dos fases principales (la generación de la base de datos y el diseño del detector de anomalías) y es representado de forma general en la Figura 2.

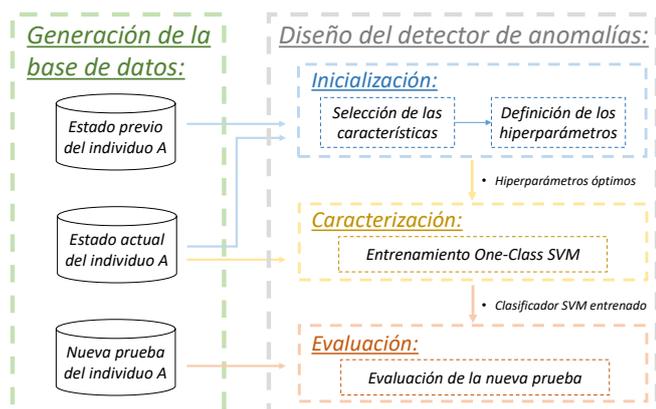


Figura 2: Metodología para el diseño de detectores de anomalías en la marcha.

3.1. Generación de la base de datos

Para poder detectar anomalías en la marcha de un paciente, es necesario disponer de una base de datos que permita caracterizar su estado actual. Para ello, en primer lugar, hay que realizar unas pruebas experimentales con el individuo, y a continuación, hay que procesar los datos capturados, preparándolos así para las siguientes fases de la metodología.

3.1.1. Pruebas experimentales

Dado que este estudio está enfocado hacia personas que necesitan un dispositivo de ayuda técnica en su día a día, las pruebas para generar la base de datos deben ser simples y no invasivas. En base a esos requerimientos, en este estudio, se plantea una prueba que consiste en caminar en línea recta un mínimo de 10 metros a una velocidad cómoda según el estado de cada persona, con la contera acoplada a su dispositivo de ayuda técnica. Esta prueba permite evaluar fácilmente la marcha de cada paciente, para poder detectar posteriormente los cambios que pueda haber en ella.

Tal como se observa en la Figura 2, la metodología propuesta requiere dos conjuntos de datos para poder proceder a la detección de anomalías. Para caracterizar el estado actual del paciente, se necesitan capturar los datos correspondientes a dicha condición, sin embargo, para poder inicializar el sistema, también se requiere disponer de datos que representen un estado previo del individuo. Así, al principio, el sistema propuesto necesita que un especialista haya identificado previamente un cambio significativo en el patrón de la marcha del paciente. Una vez realizada la inicialización, el sistema será capaz de detectar los cambios posteriores de manera automática.

3.1.2. Procesamiento de las señales

Aunque existen estudios que trabajan directamente con las señales capturadas (Delgado-Escano et al., 2019), en este trabajo, se ha optado por emplear un enfoque basado en ingeniería de características. Este enfoque facilita el manejo de datos y permite simplificar el problema, por lo que es ampliamente utilizado en estudios relacionados con el reconocimiento de la marcha y la detección de anomalías (Khera and Kumar, 2020).

En este contexto, el procesamiento de las señales tiene como objetivo generar características que permitan caracterizar los patrones individuales de la marcha. Este proceso se divide en dos fases: la segmentación y la generación de características.

En la primera fase, se realiza la segmentación de las señales, empleando para ello el procedimiento propuesto en (Mesanza et al., 2020). En este proceso, las señales son divididas en ventanas secuenciales asociadas a los ciclos de uso de la muleta, los cuales se componen de una fase de apoyo (en el que la contera está en contacto con el suelo) y una fase de movimiento (en el que no existe contacto entre el dispositivo y el suelo). Estos ciclos son fácilmente identificables utilizando la señal de fuerza proporcionada por la contera sensorizada.

La segunda fase consiste en caracterizar los segmentos obtenidos, con el objetivo de extraer información relevante que pueda ser utilizado posteriormente para detectar los cambios en la marcha. La Tabla 1 presenta las señales y los operadores estadísticos que se han utilizado en este caso para la tarea mencionada. Esta selección se ha basado en la propuesta presentada en (Mesanza et al., 2020).

Tabla 1: Características generadas ($A = Anteroposterior$; $L = Lateromedial$).

Fuente →	Acel.	Giro.	Áng.	Sensor
Operador ↓	(X, Y, Z)	(X, Y, Z)	(A, L)	fuerza
Media	X	X	X	X
Desviación estándar	X	X	X	X
Kurtosis	X	X	X	X
Coef. Correlación XY	X	X		
Coef. Correlación XZ	X	X		
Coef. Correlación YZ	X	X		
Coef. Correlación AL			X	
Percentil 25	X	X	X	X
Percentil 50	X	X	X	X
Percentil 75	X	X	X	X
Área bajo la curva	X	X	X	X
Rango intercuartil	X	X	X	X
Valor inicio apoyo			X	
Valor en fuerza máx.			X	X
Valor fin apoyo			X	
Amplitud			X	
Tiempo de ciclo				X
Fase apoyo %				X
Nº carac.	27	27	25	11

Después de llevar a cabo las dos fases que constituyen el procesamiento de las señales, se obtienen 90 características (Tabla 1) asociadas a cada ciclo de uso de la muleta.

3.2. Diseño del detector de anomalías

La estrategia de detección de anomalías propuesta en este estudio, se centra en entrenar un modelo de aprendizaje automático, empleando para ello las bases de datos generadas según el procedimiento descrito en la sección 3.1, que sea capaz de detectar los cambios que ocurran en el patrón de marcha de un paciente.

En el campo del aprendizaje automático, existen diferentes técnicas para abordar el problema de la detección de anomalías (Chandola et al., 2009). En este caso, dadas las características de la aplicación, se ha optado por emplear una técnica semi-supervisada, en la que el modelo es entrenado únicamente con datos correspondientes al estado *normal*, que en este caso, corresponderá al estado funcional actual de un paciente.

En concreto, en este estudio, se ha propuesto usar la técnica One-Class Support Vector Machine (OC-SVM), que al entrenarlo con los datos que representan el estado *normal*, genera un límite discriminativo alrededor de ellos, permitiendo determinar si un nuevo conjunto de características asociadas a un patrón de marcha es considerado del mismo estado, o por el contrario, es una anomalía, es decir, un cambio funcional (Chandola et al., 2009). Cabe destacar que, dada la variabilidad entre pacientes, el enfoque de la detección de anomalías de la marcha se implementará considerando modelos personalizados, generados a partir de los datos de cada paciente.

La Figura 2 resume el diseño del detector de anomalías, el cual se divide en tres fases: inicialización, caracterización y evaluación.

3.2.1. Inicialización

El objetivo de esta primera fase de inicialización es determinar los valores óptimos de los hiperparámetros que necesita el modelo OC-SVM en su fase de entrenamiento. Tal como se observa en la Figura 2, la fase de inicialización, está compuesta por dos etapas: la selección de las características y la definición de los hiperparámetros.

La primera etapa consiste en analizar el conjunto de 90 características definido en la sección 3.1, identificando aquellos que son más relevantes a la hora de detectar cambios significativos en el estado funcional de cada paciente. Para ello, se emplean dos conjuntos de datos: el correspondiente al estado previo de la persona monitorizada, y el correspondiente a su estado actual.

En la literatura, se proponen múltiples técnicas para la selección/extracción de las características, siendo el Principal Component Analysis (PCA) el más empleado (Khera and Kumar, 2020). Sin embargo, este algoritmo transforma las características iniciales en unas nuevas, perdiendo así el significado físico de la información inicial y la interpretabilidad de los resultados. Debido a ello, en este estudio, se ha optado por emplear el algoritmo Random Forest para la tarea mencionada, el cual, partiendo de los datos correspondientes al estado previo y al estado actual de un paciente, permite estimar la importancia relativa de cada característica en esa clasificación (Cutler et al., 2012). Una vez obtenidos los resultados, las características son ordenadas de manera decreciente según su relevancia, y aquellas que no aporten información relevante son eliminadas.

Una vez definido un conjunto representativo de características para el paciente, el siguiente paso es diseñar un clasificador

que, conociendo el estado actual de dicho paciente, deberá determinar si los nuevos datos pertenecen al mismo grupo, o por el contrario, corresponden a un *estado anómalo*. Para ello, se ha optado por el clasificador OC-SVM con un kernel de base radial (RBF), una técnica ampliamente utilizada en detección de anomalías (Hejazi and Singh, 2013; Teufl et al., 2021).

Así, la segunda etapa de inicialización consiste en seleccionar los valores de los hiperparámetros del OC-SVM y el número de características usadas para el entrenamiento, en base a lo obtenido con la técnica Random Forest.

La obtención de estos valores se realiza mediante optimización, con lo que se requieren los conjuntos de datos correspondientes al estado previo y al estado actual del paciente. El proceso se basa en entrenar varios clasificadores por cada combinación de hiperparámetros, y evaluarlos con el fin de obtener un valor representativo del rendimiento de cada combinación. Así, la combinación de hiperparámetros con el mejor rendimiento es el que se emplea en la fase de caracterización.

3.2.2. Caracterización

Una vez determinados los valores óptimos para los hiperparámetros, a continuación, se entrena el modelo OC-SVM utilizando para ello las muestras de la base de datos que representan el estado actual del paciente. Así, el modelo generado caracteriza el estado funcional *normal* del paciente, respecto al cual se detectarán los cambios posteriormente.

Nótese que, en algunos casos puede haber múltiples combinaciones óptimas de hiperparámetros. En esos casos, se entrena un clasificador para cada configuración óptima y se utilizan todos para implementar el detector, combinando sus resultados tal como se analiza en la siguiente sección.

3.2.3. Evaluación

Una vez entrenado, el clasificador OC-SVM puede ser usado periódicamente para monitorizar al paciente, determinando si los datos capturados corresponden al estado caracterizado por el modelo, o por el contrario, representan una anomalía en la marcha, que puede estar asociada a un cambio en el estado funcional del paciente.

El clasificador proporciona una salida para cada uno de los segmentos o ciclos de uso de la muleta que constituyen el conjunto correspondiente a la nueva prueba, etiquetándolos como parte del estado *normal* o como *anomalía*. Al existir varios ciclos en una misma prueba, se utiliza la estrategia de la votación y se le asigna la etiqueta predominante a la prueba, determinando así si el estado funcional del paciente ha cambiado o no.

En el caso de que existan múltiples configuraciones óptimas de hiperparámetros, y por tanto, múltiples clasificadores entrenados, se tendrá en cuenta la clasificación realizada por todos ellos, asignando a la prueba la etiqueta que más se repita entre todas ellas.

4. Validación con personas con esclerosis múltiple

La metodología propuesta en la sección 3 ha sido validada en tres personas con esclerosis múltiple que utilizan un dispositivo de ayuda técnica en su día a día. Para ello, se han realizado tres sesiones de pruebas en la Asociación de Esclerosis Múltiple de Bizkaia (ADEMBI) con la aprobación del Comité de Ética

PS2018017 del Gobierno Vasco. La Tabla 2 resume la información más relevante de los tres participantes que han colaborado en dichas sesiones.

Tabla 2: Información de los participantes.

		Paciente 1	Paciente 2	Paciente 3
Género		M	F	F
Ayuda técnica		Bastón	Muleta	Muleta
Peso (kg)	S1	91.5	57.2	58.2
	S2	92.4	55.3	59.8
	S3	95.6	54.6	57.5
SPPB	S1	8	8	7
	S2	9	11	8
	S3	9	10	7

4.1. Pruebas realizadas

Con el objetivo de monitorizar la evolución temporal de los participantes, se han llevado a cabo tres sesiones de pruebas, una cada tres meses. En cada una de ellas, los participantes han realizado dos repeticiones de una única prueba que consiste en caminar 10 metros en línea recta a una velocidad cómoda según su estado, y con la contera sensorizada acoplada a su propio dispositivo de ayuda técnica.

Además de monitorizar la marcha, en cada sesión, el estado funcional de los participantes también ha sido evaluado por un especialista, utilizando para ello la escala normalizada Short Physical Performance Battery (SPPB). Esta escala consiste en la realización de varias pruebas que tratan de evaluar el equilibrio, la fuerza y la velocidad de la marcha del paciente. La puntuación que se puede obtener oscila entre 0 y 12, siendo 12 la mejor puntuación. La Tabla 2 muestra los resultados obtenidos mediante esta evaluación en cada una de las sesiones realizadas.

Una vez ejecutadas las pruebas, se ha aplicado la metodología propuesta en la sección 3 a los datos capturados. En este caso, al tratarse de datos reales con una evolución temporal, las pruebas realizadas en las dos primeras sesiones deberían ser utilizadas para inicializar el sistema, siendo el objetivo evaluar el estado funcional del paciente en la tercera sesión. Sin embargo, de esa forma, solo se estudiaría una única casuística por paciente, lo cual proporcionaría una visión reducida del rendimiento del sistema. Con el objetivo de realizar un análisis más amplio, y dado que la metodología no está sujeta a la evolución temporal de los datos, en este estudio, se han tratado las pruebas realizadas como independientes, y han sido ordenadas de todas las combinaciones posibles, generando así múltiples casos de estudio para una misma persona.

Nótese que la metodología, tal como se ha descrito en la sección 3, necesita el estado previo y actual del paciente (entre los cuales debe haber un cambio significativo) para la inicialización. Según la evaluación de los especialistas (Tabla 2), los pacientes 1 y 3 han mantenido el mismo valor SPPB en dos de las tres sesiones realizadas, por tanto, en estos dos casos, son cuatro las combinaciones que se pueden analizar. En el caso del paciente 2, por el contrario, el valor SPPB ha variado en las tres sesiones, por lo que han sido seis los casos de estudios analizados en este paciente. La Tabla 3 muestra todas las combinaciones empleadas en esta fase de validación.

4.2. Resultados

Una vez aplicada la metodología propuesta, se han obtenido los resultados que se muestran en la Tabla 3. Cada una de las filas de esta tabla representa un caso de estudio. En ellas, se definen las sesiones utilizadas como estado previo y estado actual, siendo la sesión restante la que ha sido evaluada como *normal* o *anomalía*. Las celdas de color verde representan aquellas sesiones que el sistema ha identificado correctamente; por el contrario, las celdas de color rojo representan aquellas que han sido etiquetadas de manera incorrecta. La Tabla 3 también presenta el porcentaje de aciertos obtenido en cada paciente.

Tabla 3: Resultados de la metodología en la validación con personas con esclerosis múltiple.

	Estado previo	Estado actual	Evaluación	P. aciertos
P1	Sesión 1	Sesión 2	NORMAL	100 %
	Sesión 2	Sesión 1	ANOMALÍA	
	Sesión 1	Sesión 3	NORMAL	
	Sesión 3	Sesión 1	ANOMALÍA	
P2	Sesión 1	Sesión 2	ANOMALÍA	66.7 %
	Sesión 2	Sesión 1	ANOMALÍA	
	Sesión 1	Sesión 3	ANOMALÍA	
	Sesión 3	Sesión 1	NORMAL	
	Sesión 2	Sesión 3	ANOMALÍA	
	Sesión 3	Sesión 2	NORMAL	
P3	Sesión 1	Sesión 2	ANOMALÍA	100 %
	Sesión 2	Sesión 1	NORMAL	
	Sesión 2	Sesión 3	NORMAL	
	Sesión 3	Sesión 2	ANOMALÍA	

Los resultados muestran que, en general, la metodología identifica correctamente las pruebas de validación, con una media del 88.9 % de aciertos, lo cual está por encima del 84 % de aciertos obtenidos en estudios similares basados en sensores vestibles (Cola et al., 2015; Atallah et al., 2009). Sin embargo, cabe mencionar que, hay dos escenarios en los que la identificación no ha sido correcta: los casos de estudio 4 y 6 del participante 2. En estos casos, la metodología indica que no ha habido un cambio significativo entre las sesiones 1 y 2, sin embargo, el valor SPPB es diferente. Este fenómeno puede deberse a múltiples razones. Por un lado, puede que haya algunas características que reflejen el cambio entre esas dos sesiones y que el sistema no haya sido capaz de identificarlos como relevantes. Por otra parte, también puede ser que el patrón de marcha entre esas dos sesiones no haya cambiado significativamente, aunque el valor SPPB sea diferente. De hecho, en este caso, los resultados son congruentes, ya que los dos escenarios en los que el sistema ha fallado indican que el patrón de marcha en las sesiones 1 y 2 no ha sufrido cambios significativos.

Nótese además que, en este caso, al realizar pruebas de 10 metros, el número de muestras por cada prueba es reducido (5-7 ciclos por repetición), lo cual hace que cada muestra tenga más peso en el resultado final. Realizar pruebas más largas permitiría caracterizar mejor el estado de los pacientes, consiguiendo así modelos más robustos. Sin embargo, hay que tener en cuenta que los pacientes con esclerosis múltiple tienen problemas

de movilidad, lo cual les impide caminar largas distancias sin ayuda.

5. Conclusiones

En este trabajo se propone una metodología basada en aprendizaje automático para diseñar clasificadores que se encargarán de detectar cambios significativos en el patrón de marcha de personas con esclerosis múltiple. La propuesta se basa en los datos proporcionados por una contera sensorizada y en el uso de la técnica OC-SVM, y permite definir un modelo individualizado del estado actual del paciente, de modo que los nuevos datos capturados puedan ser evaluados. La metodología propuesta se ha validado en tres personas con esclerosis múltiple, obteniendo una media de aciertos del 88.9%. El sistema propuesto está pensado en el análisis de los parámetros de la marcha, por lo que es posible plantear su extensión a todos aquellos casos en los que los pacientes utilicen un dispositivo de ayuda técnica en su día a día, algo que se plantea como trabajo futuro.

Agradecimientos

Este trabajo ha sido realizado gracias al apoyo del Gobierno Vasco (IT1726-22), a las ayudas PID2020-112667RB-I00 y FPU19/04874 financiadas por MCI-N/AEI/10.13039/501100011033 y al proyecto Misiones Euskampus 2.0 NEUROTIP.

Los autores agradecen también a los miembros del Departamento de Fisiología de la UPV/EHU y a la Asociación de Esclerosis Múltiple de Bizkaia (ADEMBI) su colaboración en la realización de las pruebas.

Referencias

Alexander, S., Peryer, G., Gray, E., Barkhof, F., Chataway, J., 10 2021. Wearable technologies to measure clinical outcomes in multiple sclerosis: A scoping review. *Multiple Sclerosis Journal* 27, 1643–1656.
DOI: 10.1177/1352458520946005

Atallah, L., Aziz, O., Lo, B., Yang, G.-Z., 2009. Detecting walking gait impairment with an ear-worn sensor. In: 2009 Sixth International Workshop on Wearable and Implantable Body Sensor Networks. pp. 175–180.
DOI: 10.1109/BSN.2009.41

Berg-Hansen, P., Moen, S. M., Austeng, A., Gonzales, V., Klyve, T. D., Nørgård, H., Seeberg, T. M., Celius, E. G., Meyer, F., 7 2022. Sensor-based gait analyses of the six-minute walk test identify qualitative improvement in gait parameters of people with multiple sclerosis after rehabilitation. *Journal of Neurology* 269, 3723–3734.
DOI: 10.1007/s00415-022-10998-z

Brull, A., Zubizarreta, A., Cabanes, I., Rodriguez-Larrad, A., 8 2020. Sensorized tip for monitoring people with multiple sclerosis that require assistive devices for walking. *Sensors (Switzerland)* 20, 1–20.
DOI: 10.3390/s20154329

Chamorro-Moriana, G., Sevillano, J. L., Ridao-Fernández, C., 6 2016. A compact forearm crutch based on force sensors for aided gait: Reliability and validity. *Sensors (Switzerland)* 16.
DOI: 10.3390/s16060925

Chandola, V., Banerjee, A., Kumar, V., jul 2009. Anomaly detection: A survey. *ACM Computing Surveys* 41 (3).
DOI: 10.1145/1541880.1541882

Cola, G., Avvenuti, M., Vecchio, A., Yang, G. Z., Lo, B., 11 2015. An on-node processing approach for anomaly detection in gait. *IEEE Sensors Journal* 15, 6640–6649.
DOI: 10.1109/JSEN.2015.2464774

Cutler, A., Cutler, D. R., Stevens, J. R., 2012. Random forests. *Ensemble Machine Learning*, 157–175.
DOI: 10.1007/978-1-4419-9326-7_5

Delgado-Escano, R., Castro, F. M., Cozar, J. R., Marin-Jimenez, M. J., Guil, N., 2019. An end-to-end multi-task and fusion cnn for inertial-based gait recognition. *IEEE Access* 7, 1897–1908.
DOI: 10.1109/ACCESS.2018.2886899

Dobson, R., Giovannoni, G., 1 2019. Multiple sclerosis – a review. *European Journal of Neurology* 26, 27–40.
DOI: 10.1111/ene.13819

Fernandez, I. G., Ahmad, S. A., Wada, C., 9 2020. Inertial sensor-based instrumented cane for real-time walking cane kinematics estimation. *Sensors (Switzerland)* 20, 1–19.
DOI: 10.3390/s20174675

Flachenecker, P., 2015. Clinical implications of neuroplasticity - the role of rehabilitation in multiple sclerosis. *Frontiers in Neurology* 6.
DOI: 10.3389/fneur.2015.00036

Greene, B. R., Rutledge, S., McGurgan, I., McGuigan, C., O'Connell, K., Caulfield, B., Tubridy, N., 2015. Assessment and classification of early-stage multiple sclerosis with inertial sensors: Comparison against clinical measures of disease state. *IEEE Journal of Biomedical and Health Informatics* 19.
DOI: 10.1109/JBHI.2015.2435057

Hejazi, M., Singh, Y. P., 5 2013. One-class support vector machines approach to anomaly detection. *Applied Artificial Intelligence* 27, 351–366.
DOI: 10.1080/08839514.2013.785791

Khera, P., Kumar, N., 11 2020. Role of machine learning in gait analysis: a review. *Journal of Medical Engineering and Technology* 44, 441–467.
DOI: 10.1080/03091902.2020.1822940

Mesanza, A. B., Lucas, S., Zubizarreta, A., Cabanes, I., Portillo, E., Rodriguez-Larrad, A., 2020. A machine learning approach to perform physical activity classification using a sensorized crutch tip. *IEEE Access* 8, 210023–210034.
DOI: 10.1109/ACCESS.2020.3039885

Müller, R., Hamacher, D., Hansen, S., Oschmann, P., Keune, P. M., 12 2021. Wearable inertial sensors are highly sensitive in the detection of gait disturbances and fatigue at early stages of multiple sclerosis. *BMC Neurology* 21.
DOI: 10.1186/s12883-021-02361-y

Rotstein, D., Montalban, X., 5 2019. Reaching an evidence-based prognosis for personalized treatment of multiple sclerosis. *Nature Reviews Neurology* 15, 287–300.
DOI: 10.1038/s41582-019-0170-8

Souza, A., Kelleher, A., Cooper, R., Cooper, R. A., Iezzoni, L. I., Collins, D. M., 2010. Multiple sclerosis and mobility-related assistive technology: Systematic review of literature. *Journal of Rehabilitation Research and Development* 47, 213–224.
DOI: 10.1682/JRRD.2009.07.0096

Sun, R., Moon, Y., McGinnis, R. S., Seagers, K., Motl, R. W., Sheth, N., Wright, J. A., Ghaffari, R., Patel, S., Sosnoff, J. J., 2018. Assessment of postural sway in individuals with multiple sclerosis using a novel wearable inertial sensor. *Digital Biomarkers* 2, 1–10.
DOI: 10.1159/000485958

Teuff, W., Taetz, B., Miezal, M., Dindorf, C., Fröhlich, M., Trinler, U., Hogan, A., Bleser, G., 10 2021. Automated detection and explainability of pathological gait patterns using a one-class support vector machine trained on inertial measurement unit based gait data. *Clinical Biomechanics* 89.
DOI: 10.1016/j.clinbiomech.2021.105452

Vajitha Begum, S. A., Rani, M. P., 2020. Recognition of neurodegenerative diseases with gait patterns using double feature extraction methods. In: 2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS). pp. 332–338.
DOI: 10.1109/ICICCS48265.2020.9120920