

Apéndice C. Resultados de la revisión sistemática de literatura

Tabla 23. Hallazgos clave y limitaciones de los estudios incluidos en la revisión sistemática

N°	Artículo	Key Findings	Limitations
1	A Deep Learning Approach for Gait Event Detection from a Single Shank-Worn IMU	CNN dilatada detecta contactos iniciales y finales con precisión 97% en 157 sujetos (sanos y patológicos).	No analiza desempeño con sensores en otras ubicaciones.
2	A Deep Learning Approach for TUG and SPPB Score Prediction of (Pre-) Frail Older Adults on Real-Life IMU Data	DNN predice scores funcionales (TUG, SPPB) con precisión ~95% usando IMU en la cintura.	Tamaño de muestra pequeño (20 sujetos); limitado a población frágil.
3	Accurate detection of gait events using neural networks and IMU data mimicking smartphone usage (2024)	CNN+BiLSTM+DNN logró 92% accuracy (87–96%); error temporal ≈32 ms; detección precisa de HS y TO usando IMU en mano, bolsillo y chaqueta.	Solo 52 adultos sanos ; pruebas en cinta, no en vida diaria; sin validación en poblaciones clínicas.
4	Accurate fall risk classification in elderly using one gait cycle data (2024)	LightGBM alcanzó 93.6% accuracy , F1=0.934 ; edad y parámetros de aceleración/velocidad angular fueron los predictores más relevantes; posible clasificar riesgo con un solo ciclo de marcha.	Solo 44 adultos mayores ; todos caminaban de forma independiente; validado con un único smartphone en región sacra.
5	Automatic Detection of Fatigued Gait Patterns in Older Adults	Wrapper Feature Selection permite diferenciar marcha fatigada vs normal con 99% de precisión en adultos mayores.	Solo 18 sujetos; posible sobreajuste por muestra pequeña.
6	Detecting Human Gait Phases and Conditions with Deep Learning	RNN permite distinguir fases y condiciones normales y patológicas de la marcha con un solo IMU.	No se reporta precisión numérica exacta; falta validación en distintos grados de severidad patológica.
7	Development of Gait Classification System Using CNN-LSTM	CNN-LSTM diferencia marcha normal y hemiparesia a partir de señales IMU en rodillas. El modelo es generalizable.	Simulación de hemiparesia en sanos; muestra pequeña (5 sujetos); sin métricas de precisión claras.
8	Distinguish between Obese and Normal Body Types through Gait Analysis	IMU en rodilla distingue con 92% de precisión sujetos obesos vs normales, correlacionando parámetros como cadencia y longitud de paso.	Solo 8 sujetos; no analiza otras patologías o rangos de edad.
9	Distinguishing Pathologic Gait in Older Adults Using Instrumented Insoles and Deep Neural Networks	DNN sobre plantillas instrumentadas distingue tipos de marcha patológica y saludable en adultos mayores, AUC 0.88-0.98 según patología.	No detalla validación longitudinal; posible sesgo de selección.
10	Fall risk assessment of aged workers using wearable IMU (2021)	Random Forest alcanzó 91.07% accuracy ; se usó un IMU lumbar para clasificar riesgo de caídas en trabajadores mayores con parámetros de paso, cadencia y variabilidad.	Muestra reducida , condiciones controladas; no incluye pacientes con patologías ni validación en escenarios laborales reales.
11	Gait Phase Estimation by Using LSTM in IMU-Based Gait Analysis	LSTM identifica fases clave (Foot-Off, Mid-Swing, Foot-Contact) con IMUs en tobillos en sujetos sanos.	Solo población sana; sin validación en patologías.
12	Gait-Based Parkinson's Disease Diagnosis and Severity Classification Using Force Sensors and Machine Learning	Random Forest y Ensemble Regressor logran 97.5% (diagnóstico) y 96.4% (severidad) en Parkinson usando sensores de fuerza en ambos pies.	No analiza generalización a otras enfermedades neurodegenerativas.
13	IMU Signal-Based Machine Learning Methods for Frailty Assessment in Geriatric Health	InceptionTime (DL) predice niveles de fragilidad con 98% precisión usando IMU en pie.	No analiza evolución longitudinal de la fragilidad.
14	Kinematic Analysis of Human Gait Using IMU Sensors	SVM (kernel cúbico) alcanza 92.4% de precisión identificando fases del ciclo de marcha. Se proponen "spider plots" para diagnóstico personalizado.	Muestra solo incluye adultos jóvenes sanos, lo que limita la generalización.
15	Machine Learning Based Abnormal Gait Classification with IMU Considering Joint Impairment	SVM, RF y XGB logran >91% precisión al clasificar marcha normal, rodilla y tobillo simulado mediante IMU en muslo y pierna.	Simulación de patologías en sanos; no incluye pacientes reales.
16	Machine Learning for Early Detection and Severity Classification in Parkinson's Disease	IMU en calzado y ML logran 78.1% en clasificación general, 67-70% en etapas tempranas y severidad de Parkinson.	Precisión menor en detección temprana; no se exploran estrategias para aumentar sensibilidad.
17	Machine Learning-Based Estimation of Dynamic Balance and Gait Adaptability in Persons with Neurological Diseases	Elastic-Net Regression estima equilibrio dinámico (mDGI) en pacientes neurológicos con error mediano bajo.	No compara contra otros modelos; no valida robustez en diferentes entornos.

18	Machine Learning-Based Gait Characterization Using Single IMU Sensor	SVM, LDA y KNN caracterizan marcha con precisión 91.9-97% usando IMU única en tobillo.	Solo 5 sujetos; no valida en pacientes con alteraciones de la marcha.
19	Methodology and Validation for Identifying Gait Type Using Machine Learning on IMU Data	ANN logra 94% de precisión en clasificación de tipo de marcha (caminar, trotar, correr) con IMU en tobillo.	Muestra limitada a adultos sanos y laboratorio.
20	ML algorithms with a single IMU for surface- and age-related differences (2018)	LSTM logró 96.3% accuracy (superficie) y 94.7% (edad) con un IMU lumbar; AUC ≈ 0.97 ; detección robusta con un único sensor.	Solo 35 sanos ; muestra reducida; entornos limitados (plano e irregular), no vida diaria.
21	ML approach to support detection of Parkinson's Disease in IMU-based gait analysis (2022)	Con un IMU en L5, SVM alcanzó 86% accuracy , F1=85% ; detectó HS/TO y fases de marcha, diferenciando PD vs. controles.	Solo pacientes PD HY 1-3 ; caminata en pasillo controlado; sin considerar factores como medicación o fatiga.
22	Predicting physical activity levels from kinematic gait data using ML (2023)	RF alcanzó 84.04% accuracy ; NCA permitió seleccionar las características más relevantes; con 4 IMUs en EE.II. se logró buena predicción de niveles de actividad física (IPAQ).	37 sujetos sanos en entorno controlado; muestra pequeña y homogénea; sin poblaciones clínicas ni de edad avanzada.
23	The Detection of Age Groups by Dynamic Gait Outcomes Using Machine Learning	ANN, SVM y RF diferencian grupos etarios y patologías con acelerómetro en tronco, precisión hasta 90%.	No se prueba en escenarios clínicos; posible sesgo poblacional.
24	Using ML and wearable IMU data for classification of fractal gait patterns (2023)	Se aplicó DFA y ML (SVM, RF, k-NN, MLP); resultados moderados (50-75%); mejor desempeño en shank izquierdo (80.1% accuracy).	Ningún modelo superó 90%; desempeño dependió de la ubicación del IMU; muestra pequeña y homogénea.
25	Wearable Sensor-Based Gait Analysis for Age and Gender Estimation	Temporal ConvNet con IMU en la cintura estima edad y género de los sujetos con alto rendimiento en cohortes grandes.	No se testea en poblaciones clínicas ni en condiciones adversas.
26	Implementation of machine learning algorithms for gait recognition	RF, IB1 y BayesNet: >99% precisión con IMUs. Voting mejora robustez. Validación cruzada y sensores en piernas/pies.	No diferencia grupos etarios. Pocos sujetos, todos adultos sanos. Datos controlados.
27	XGBoost based machine learning approach to predict the risk of fall in older adults using gait outcomes	Uso de IMUs integrados en calzado para extraer parámetros de marcha. El modelo XGBoost predice el riesgo de caídas con precisión.	Precisión moderada (AUC 0.67-0.70), no adecuada para diagnóstico individual. Falta validación externa en otras poblaciones.
28	Wearable Sensor-Based Gait Classification in Idiopathic Toe Walking Adolescents	IMU en la zona lumbar permitió diferenciar entre marcha toe-toe y heel-toe en adolescentes con ITW. LSTM logró 94.3% de precisión, superando a k-means (82%). El enfoque no requiere segmentación manual, útil para monitoreo automático.	Muestra pequeña (5 adolescentes con ITW).- Solo se probó en un tipo específico de alteración de marcha.- No evalúa la generalización a otras edades o patologías.
29	Applying Machine Learning to Gait Analysis Data for Disease Identification	RF, SVM y MLP logran 100% de precisión clasificando tipos de enfermedad (saludable, NND, JIA). Se emplean 19 parámetros temporoespaciales. Metodología puede acelerar diagnóstico clínico.	- Tamaño muestral pequeño (28 niños/adolescentes). No utiliza IMUs, sino sistema de captura óptica 3D. Validación cruzada, pero sin pruebas en otros centros o cohortes.
30	Using Inertial Sensors for Step Counting and Gait Phase Detection to Evaluate Free-Living Walking in Parkinson's Disease	Un solo IMU en zona lumbar permite detectar pasos y fases de la marcha (stance/swing) en Parkinson y controles. Precisión alta: 96.1% para pasos, 91.4% para fases. Método útil para monitoreo remoto.	Muestra pequeña (10 sujetos; 6 Parkinson, 4 controles).- Solo evalúa fases básicas; no identifica eventos finos como heel strike.
31	Systematic Comparison of the Influence of Different Data Preprocessing Methods on the Performance of Gait Classifications Using Machine Learning	Preprocesamiento (PCA, filtrado GRF) mejora precisión de ML en clasificación de marcha con plataformas de fuerza; mejores resultados con PCA supervisado.	Solo adultos sanos; no usa IMUs, sino plataformas de fuerza; no aplica a diferencias por edad.
32	Human lower-extremity movement classification based on biomechanical sensor data: Machine learning approach	La combinación IMU+GON elevó la precisión hasta 96.1%, modelos basados únicamente en EMG obtuvieron 73.5%. Además, se confirmó que la longitud de ventana de 5 segundos optimiza el rendimiento, y que los clasificadores QSVM superan a WNN y ESKNN.	Implementación en MATLAB y con algoritmos tradicionales, dejando fuera modelos de deep learning que podrían mejorar la robustez y aplicabilidad en entornos reales

33	Accurate Ambulatory Gait Analysis in Walking and Running Using Machine Learning Models.	SVR logró alta precisión en la estimación de parámetros de la marcha. En caminata, los errores fueron muy bajos, aumentaron en carrera.	El estudio se limitó por una muestra pequeña y homogénea (14 varones sanos) y pruebas solo en caminadora. Los modelos genéricos redujeron su precisión en tareas dinámicas y el SVR dependió de la selección de features e hiperparámetros.
34	Classification of Inertial Sensor-Based Gait Patterns of Orthopaedic Patients Using Convolutional Neural Networks	CNN con IMUs en tibia, muslo y sacro; precisión hasta 95.4% para distinguir marcha anómala postquirúrgica.	Solo ortopédicos y controles; no diferencia por edad; usa ventanas de señal sin segmentar eventos.
35	Applied Machine Learning on Phase of Gait Classification and Joint-Moment Regression	Random Forest fue el mejor clasificador; las caderas aportan más información; con 3 articulaciones se mantiene alta precisión; el modelo Extra Trees estima momentos por fase, habilitando requerimientos de torque por transición.	Datos de adultos sanos y análisis solo en el plano sagital; variabilidad entre bases públicas y dependencia de ángulos articulares (sin EMG/plantar). La regresión de momentos presenta R^2 moderados en varias fases, lo que puede limitar la generalización clínica.
36	Machine Learning-Based Predicted Age of the Elderly on the Instrumented Timed Up and Go Test and Six-Minute Walk Test	IMU en L2; XGBoost predice edad funcional con buen ajuste ($R^2=0.84$) usando pruebas TUG y 6MWT.	Solo adultos mayores (60–90 años); no compara con jóvenes; predicción de edad, no de patologías.
37	Using Machine Learning Algorithms for Identifying Gait Parameters Suitable to Evaluate Subtle Changes in Gait in People with Multiple Sclerosis	La velocidad y la longitud de paso son los rasgos más útiles. SVM y KNN fueron los algoritmos con mejor rendimiento. La especificidad superó a la sensibilidad en la mayoría de casos. DIERS funcionó mejor para distinguir sanos vs EM, y GAITrite para detectar fatiga y diferenciar niveles de EDSS.	Falta de validación externa, solo se usó validación cruzada repetida (riesgo de sobreestimación). Clases desbalanceadas y sensores heterogéneos, que afectan la consistencia de resultados. Rendimiento moderado ($\kappa=0.49-0.61$), insuficiente aún para una aplicación clínica amplia.
38	Automated Activity Recognition with Gait Positions Using Machine Learning Algorithms	Random Forest algoritmo más robusto, logrando 81–82% de precisión en el reconocimiento de actividades. El uso de sensores en tobillos, cinturón y pecho permitió clasificar 11 actividades, incluyendo transiciones y caídas, relevante para el diseño de sistemas de rehabilitación y monitoreo clínico.	Subconjuntos muy pequeños, clases desbalanceadas; al eliminar los timestamps se perdió información temporal relevante para la marcha, validación se realizó únicamente en entorno offline con WEKA.
39	Prediction of Decline in Global Cognitive Function Using Machine Learning with Feature Ranking of Gait and Physical Fitness Outcomes in Older Adults	La selección de rasgos reduce el error; EN rindió mejor en hombres y SVM en mujeres; los rasgos de variabilidad/fase de la marcha y cadencia destacan, junto con fuerza de prensión, sit-to-stand, equilibrio unipodal, resistencia y escolaridad	Redicción continua (MMSE) sin punto de corte clínico, dependencia de MMSE (sensibilidad limitada), y enfoque de ranking acumulativo que puede omitir combinaciones óptimas; resultados sexoespecíficos que requieren replicación.
40	Biometric Gait Recognition Based on Machine Learning Algorithms	El enfoque silueta simplifica el cómputo y mantiene buena capacidad de discriminación. ANN fue el mejor clasificador, SVM y k-NN lograron rendimientos cercanos (~85%), pero dependen más del tamaño de entrenamiento y de los parámetros.	Desempeño sensible a ropa/calzado/terreno/fatiga/lesión y ángulo de cámara; se reportan falsos positivos que impiden sustituir a rostro/huella; uso principal de SVM lineal y ANN (sin validación externa profunda); los autores señalan CNN y biometría multimodal como trabajo futuro.
41	A Machine Learning Framework for Gait Classification Using Inertial Sensors: Application to Elderly, Post-Stroke and Huntington's Disease Patients	IMUs en tibias y lumbar; HMM+SVM clasifican patrones patológicos de marcha con 90.5% de precisión.	Solo 42 sujetos; no compara con adultos jóvenes; estudio transversal, no longitudinal.
42	Normal and pathological gait classification LSTM model	Los ángulos cinemáticos superan a usar posiciones de 24–34 articulaciones, que bajan la exactitud a 48%; el ensamble de LSTM reduce la varianza entre particiones; LSTM supera a SVM. En la partición fija, el modelo logró alta precisión: para rigidez 95% sensibilidad y 98% especificidad; para cojera 87% y 97%.	Patologías simuladas (plantilla/rodilla rígida), muestra limitada y dependencia de Kinect (errores de tobillo/pies); precisión aún insuficiente para uso clínico directo; resultados sensibles a la partición de sujetos

43	Clinical Human Gait Classification: Extreme Learning Machine Approach	Los modelos SVM y ELM fueron los mejores en clasificación en sujetos sanos, con esclerosis múltiple y con ACV, pero con más errores en los tipos de crouch gait. El ELM alcanzó una alta precisión (93.5%), con predicciones rápidas y mejor desempeño que MLP o KNN	Desbalance de clases, sin validación externa, solo características cinemáticas. Parte de los datos de Crouch proviene de OpenSim; la conversión de acelerometría a ángulos puede introducir errores y limitar la generalización clínica.
44	Wearable Sensor-Based Prediction Model of Timed up and Go Test in Older Adults	Es posible predecir el puntaje clínico TUG. Identifica que un solo sensor en pelvis ofrece desempeño comparable a sensores en pies. Las variables más predictivas se relacionan con magnitud del paso y doble apoyo, fases clave para estabilidad y riesgo de caída.	Muestra reducida (n=37). La recolección de datos se realizó en un entorno semi-controlado, alto número de predictores en relación con el tamaño muestral, no se incluyeron participantes con patologías neurológicas o alto riesgo de caídas
45	Machine Learning Approach for Automated Detection of Irregular Walking Surfaces for Walkability Assessment with Wearable Sensor	El tobillo es la mejor ubicación para el sensor al detectar superficies irregulares. El SVM fue el algoritmo más robusto, la técnica permite una evaluación objetiva y continua de la walkability en entornos urbanos.	Pocos sujetos (n=12) y entorno experimentado (no barrios reales); solo adultos sanos; una sola localización de sensor en el despliegue; falta validación externa; el rendimiento reportado es AUC, no exactitud clínica.
46	Human Gait Activity Recognition Machine Learning Methods	IMUs y sensor de esfuerzo en tibias y gemelo; CNN+RNN detectan actividades de marcha y freezing of gait (FOG) en Parkinson (98.9%).	Solo 5 sujetos; mayoría sanos; estudio piloto; no analiza diferencias por edad.
47	Gait Stride Length Estimation Using Embedded Machine Learning	Un solo IMU en el empeine permite estimar la longitud de zancada con alta precisión. La cuantización a int8 redujo latencia y memoria sin afectar la precisión.	Muestra pequeña (15 sujetos sanos, jóvenes). Evaluación solo en cinta de caminar, no en condiciones reales. Sin validación clínica en poblaciones con patologías
48	Using Lower Limb Wearable Sensors to Identify Gait Modalities: A Machine-Learning-Based Approach	El método 2D-FT, PCA, DFA distingue bien cambios de velocidad en la marcha. La ubicación del sensor en el sacro es la más precisa, y la tibia también ofrece alta exactitud y resulta práctica para aplicaciones como prótesis y órtesis	El estudio se hizo solo con personas sanas en condiciones de laboratorio, evaluando únicamente tres velocidades de marcha. Además, la exactitud se calculó con un criterio propio (≥ 500) en lugar de métricas estándar.
49	Latest Research Trends in Gait Analysis Using Wearable Sensors and Machine Learning: A Systematic Review	Revisión de estudios con IMUs, EMG, presión, plantillas; precisión de 85–99%; cubre diagnóstico, monitoreo y rehabilitación.	No datos propios; variabilidad en métodos y poblaciones; resultados no directamente comparables.
50	Gait Speed and Task Specificity in Predicting Lower-Limb Kinematics: A Deep Learning Approach Using Inertial Sensors	Desarrollo de un sistema con Transmisión inalámbrica (Bluetooth) y análisis en smartphone o nube en tiempo real. Capacidad de extraer 12 características críticas de la marcha: velocidad, longitud de zancada, cadencia, presión plantar, orientación del pie, tiempo de oscilación, etc.)	El estudio reporta resultados preliminares con un solo sujeto. No se incluyen pruebas de precisión cuantitativa comparadas con sistemas de referencia clínicos

Nota. La tabla presenta los 50 artículos incluidos en la síntesis sistemática tras la aplicación del protocolo PRISMA 2020 (Page et al., 2021). Elaboración propia.